

**UNIVERSIDAD POLITÉCNICA SALESIANA  
SEDE QUITO**

**CARRERA:  
INGENIERÍA AMBIENTAL**

**Trabajo de titulación previo a la obtención del título de:  
INGENIERAS AMBIENTALES**

**TEMA:  
ESTABLECIMIENTO DE MODELOS PARAMETRIZADOS PARA  
ESTIMACIÓN DE POSIBLE PRESENCIA DE CONTAMINACIÓN Y  
ENFERMEDAD DEL SUELO MEDIANTE DRONES EN LA ZONA  
COSTERA**

**AUTORAS:  
  
JOSELIN MARÍA QUINTANA CHÁVEZ  
KAREN TATIANA TITUAÑA PILLAJO**

**TUTOR:  
CÉSAR IVÁN ÁLVAREZ MENDOZA**

**Quito, agosto del 2019**

## CESIÓN DE DERECHOS DE AUTORES

Nosotras Joselin María Quintana Chávez con documento de identificación N° 1722651203 y Karen Tatiana Tituaña Pillajo con documento de identificación N° 1719136556, manifestamos nuestra voluntad y cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos autoras del trabajo de titulación intitulado: **ESTABLECIMIENTO DE MODELOS PARAMETRIZADOS PARA ESTIMACIÓN DE POSIBLE PRESENCIA DE CONTAMINACIÓN Y ENFERMEDAD DEL SUELO MEDIANTE DRONES EN LA ZONA COSTERA**, mismo que ha sido desarrollado para optar por el título de: INGENIERAS AMBIENTALES, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En aplicación a lo determinado en la Ley de Propiedad Intelectual, en nuestra condición de autoras nos reservamos los derechos morales de la obra antes citada. En concordancia, suscribimos este documento en el momento que hacemos entrega del trabajo final en formato impreso y digital a la Biblioteca de la Universidad Politécnica Salesiana.



Joselin María Quintana Chávez  
1722651203



Karen Tatiana Tituaña Pillajo  
1719136556

Fecha: Agosto 2019

## DECLARATORIA DE COAUTORÍA DEL TUTOR

Yo declaro que bajo mi dirección y asesoría fue desarrollado el Trabajo Experimental, **ESTABLECIMIENTO DE MODELOS PARAMETRIZADOS PARA ESTIMACIÓN DE POSIBLE PRESENCIA DE CONTAMINACIÓN Y ENFERMEDAD DEL SUELO MEDIANTE DRONES EN LA ZONA COSTERA** realizado por Joselin María Quintana Chávez y Karen Tatiana Tituaña Pillajo, obteniendo un producto que cumple con todos los requisitos estipulados por la Universidad Politécnica Salesiana, para ser considerados como trabajo final de titulación.

Quito, agosto de 2019



CESAR IVÁN ÁLVAREZ MENDOZA

C.I. 1720100922

## **DEDICATORIA**

El presente trabajo está dedicado a Dios, que ha sido mi roca, salvador y fortaleza, a mi padre William Quintana, una persona positiva y sonriente que a pesar de la distancia siempre me brinda su amor y apoyo incondicional, a mi madre Mariana Chávez, una mujer luchadora que me ha enseñado a valorar la vida, y que a pesar de las adversidades siempre hay una luz en el camino, gracias mamá y papá por su paciencia, por ser como son, por ser mi sustento y motivación para seguir adelante día a día y permitirme culminar una etapa más en mi vida.

**Joselin**

El presente trabajo le dedico a Dios por darme la vida, la salud y la fuerza para cumplir con uno de mis sueños.

A mi padre Fabián Tituaña quien gracias a su esfuerzo, que a pesar de la distancia y de las adversidades siempre ha sido en todos los aspectos un sustento para poder cumplir una parte de mi sueño, a mi madre Adriana Pillajo, por su sacrificio, su amor, comprensión y apoyo diario que sin esto no hubiera podido afrontar los obstáculos que se me planteaban, a mis hermanos Samantha y Cristian por haberse convertido en mi motivación para ser mejor cada día y a mis abuelitos quienes me han acompañado durante toda mi formación educativa y han sido una parte esencial para poder realizar este sueño.

Y a todos aquellos que me han brindado su amor, su valiosa amistad y sus conocimientos, quienes me han ayudado hacer de este camino una travesía llena de experiencias maravillosas.

**Karen**

## **AGRADECIMIENTO**

En primer lugar, agradecemos a Dios por salvaguardar nuestra vida y otorgarnos la sabiduría necesaria para culminar este trabajo investigativo.

Agradecemos a nuestros padres por todo el amor, la paciencia y el apoyo, brindado a lo largo de nuestras vidas.

A nuestro tutor de tesis PhD Cesar Iván Álvarez Mendoza, por los conocimientos, consejos, ayuda y guía brindada durante el desarrollo de nuestro trabajo.

A todos nuestros docentes por sus enseñanzas académicas que nos formaron como profesionales.

Finalmente, a la Universidad Politécnica Salesiana por ser nuestro segundo hogar y apoyarnos para el desarrollo de este estudio.

## ÍNDICE

1.	INTRODUCCIÓN.....	1
2.	OBJETIVOS .....	3
2.1.	Objetivo General .....	3
2.1.	Objetivos específicos .....	3
3.	MARCO TEÓRICO .....	4
3.1.	El suelo.....	4
3.2.	Indicadores de calidad del suelo .....	4
3.2.1.	Indicadores físicos.....	4
3.2.1.1.	Textura.....	5
3.2.1.2.	Humedad .....	5
3.2.2.	Indicadores químicos .....	5
3.3.	Características generales del cultivo .....	7
3.3.1.	Hábitat y requerimientos de desarrollo .....	8
3.3.2.	Ciclo de desarrollo .....	8
3.4.	Sensores remotos.....	9
3.4.1.	Vehículo aéreo no tripulado (UAV) .....	9
3.5.	Índices espectrales.....	12
3.5.1.	NDVI .....	13
3.5.2.	SMI (Soil moisture index) .....	13
3.5.3.	NDRE.....	14
3.5.4.	GNDVI.....	14

3.5.5.	NDWI.....	15
3.6.	Softwares empleados .....	15
3.6.1.	eMotion 3.5.0.....	15
3.6.2.	Pix4D .....	16
3.6.3.	ArcGIS .....	17
3.6.4.	Rstudio.....	17
3.6.4.1.	Paquete “caret” .....	17
3.6.4.2.	Paquete “Corrplot”.....	17
3.6.4.3.	Paquete “Car” .....	18
3.6.4.5.	Paquete “GGally” .....	18
3.6.4.6.	Paquete “lmtest” .....	18
3.7.	Modelo de regresión lineal.....	19
3.7.1.	Análisis de correlación.....	19
<b>3.7.1.3.</b>	<b>Coefficiente de correlación de Pearson .....</b>	<b>19</b>
3.7.2.	Modelo de regresión lineal simple (MRLS) .....	20
3.7.2.1.	Método de mínimos cuadrados .....	20
3.7.3.	Supuestos del modelo .....	23
3.7.4.	Diagnóstico del modelo MRL.....	23
3.7.5.	Prueba de Durbin Watson.....	26
3.7.6.	Prueba Shapiro Wilk.....	26
3.7.7.	Prueba de contraste Breusch-Pagan.....	26
3.7.8.	Criterio de información Akaike .....	27

3.7.9.	Métricas de rendimiento del modelo .....	27
3.7.10.	Validación cruzada K-Fold.....	27
3.7.11.	Predicción de los modelos de regresión.....	28
4.	METODOLOGÍA .....	29
4.1.	Descripción de las zonas de estudio.....	29
4.1.1.	Primera área de estudio.....	29
4.1.2.	Segunda área de estudio.....	30
4.2.	Fases de estudio .....	32
4.2.1.	Fase de planificación .....	32
4.2.1.1.	Planificación de los vuelos .....	32
4.2.1.2.	Muestreo de suelo .....	33
4.2.2.	Fase de campo.....	35
4.2.2.1.	Toma de muestras .....	35
4.2.2.2.	Recolección de imágenes aéreas.....	36
4.2.3.	Fase de análisis - parámetros del suelo.....	37
4.2.3.1.	Determinación de nitrógeno total .....	37
4.2.3.2.	Determinación de materia orgánica .....	37
4.2.3.3.	Análisis en laboratorio .....	38
4.2.3.3.1.	Preparación de la muestra .....	38
4.2.3.3.3.	Determinación de humedad. ....	40
4.2.3.3.5.	Determinación de Fósforo .....	40
4.2.4.	Procesamiento de la información.....	43



4.2.4.1.	Generación de raster térmicos.....	43
4.2.4.2.	Obtención de orto fotos.....	44
4.2.4.3.	Calculo de NDVI .....	44
4.2.4.4.	Calculo de SMI (Soil moisture index) .....	45
4.2.4.5.	Calculo de NDRE .....	46
4.2.4.6.	Calculo de GNDVI .....	47
4.2.4.7.	Calculo de NDWI .....	48
4.3.	Diseño del modelo.....	49
4.3.1.	Planteamiento de la hipótesis.....	50
4.3.2.	Modelo de regresión lineal .....	50
4.3.2.1.	Aplicación de la correlación de datos .....	51
4.3.2.2.	Ejecución del MRLS.....	51
4.3.2.3.	Prueba de Durbin Watson .....	52
4.3.2.4.	Prueba Shapiro Wilk.....	52
4.3.2.5.	Prueba de contraste Breusch-Pagan.....	52
4.3.2.6.	Predicción del modelo .....	52
4.3.2.7.	Criterio de información Akaike .....	52
4.3.2.8.	Validación cruzada K-Fold.....	52
5.	RESULTADOS Y DISCUSIÓN.....	55
5.1.	Resultados de los parámetros de calidad del suelo .....	55
5.2.	Resultados de los índices de reflectancia espectral.....	56
5.3.	Análisis de correlación.....	58

5.4.	Variables empleadas para los modelos .....	60
5.5.	MRL para la estimación de contenido de nitrógeno .....	60
5.5.1.	Evaluación de los supuestos de regresión lineal .....	61
5.4.1.1.	Parcelas de diagnóstico .....	61
5.5.2.	Ecuaciones de MRL para la obtención de Nitrógeno .....	68
5.6.	MRL para la estimación de contenido de MO .....	68
5.6.1.	Evaluación de supuestos de regresión lineal.....	69
5.7.	MRL para la estimación de contenido de fósforo .....	74
5.7.1.	Evaluación de supuestos de regresión lineal.....	75
5.7.2.	Selección y validación del mejor modelo .....	78
5.8.	MRL para la valoración de contenido de humedad .....	80
5.8.1.	Evaluación de los supuestos de regresión lineal .....	81
5.8.2.	Ecuaciones de MRL para la estimación de humedad .....	85
5.9.	Mapas de estimación de parámetros .....	86
5.10.	Discusión general .....	95
6.	CONCLUSIONES Y RECOMENDACIONES .....	99
6.1.	Conclusiones .....	99
6.2.	Recomendaciones.....	100
7.	BIBLIOGRAFÍA.....	101

## ÍNDICE DE TABLAS

<b>Tabla 1</b>	Regla de decisión para la prueba Durbin Watson .....	26
<b>Tabla 2</b>	Tipo de suelo de acuerdo a sus rangos de pH.....	39
<b>Tabla 3</b>	Parámetros de calidad del suelo para el área 1. ....	55
<b>Tabla 4</b>	Parámetros de calidad del suelo para el área 2. ....	56
<b>Tabla 5</b>	Índices de reflectancia espectral para el área 1. ....	57
<b>Tabla 6</b>	Índices de reflectancia espectral para el área 2. ....	57
<b>Tabla 7</b>	Variables dependientes e independiente empleadas en los modelos.....	60
<b>Tabla 8</b>	Resumen estadístico de los coeficientes del modelo de regresión de N	60
<b>Tabla 9</b>	Resumen estadístico de la bondad de ajuste del modelo de regresión ...	61
<b>Tabla 10</b>	Pruebas de diagnóstico aplicadas al MRL de N. ....	65
<b>Tabla 11</b>	Selección y validación del mejor modelo - N. ....	66
<b>Tabla 12</b>	Ecuaciones planteadas para determinación de N. ....	68
<b>Tabla 13</b>	Resumen estadístico del modelo de regresión de MO .....	68
<b>Tabla 14</b>	Resumen de bondad y ajuste del modelo de regresión de MO. ....	69
<b>Tabla 15</b>	Pruebas de diagnóstico de supuestos de regresión para MO.....	71
<b>Tabla 16</b>	Valores de validación cruzada y criterio Akaike para MO. ....	72
<b>Tabla 17</b>	.Ecuaciones para la estimación de MO. ....	73
<b>Tabla 18</b>	Resumen estadístico del modelo de regresión de P.....	74
<b>Tabla 19</b>	Resumen de bondad y ajuste de modelo de regresión de P.....	74
<b>Tabla 20</b>	Pruebas de diagnóstico de supuestos de regresión para P. ....	78
<b>Tabla 21</b>	Valores de validación cruzada y criterio Akaike para P. ....	78
<b>Tabla 22</b>	Ecuaciones para la estimación de P.....	79
<b>Tabla 23</b>	Resumen estadístico de coeficientes del MRL humedad .....	80

<b>Tabla 24</b> Resumen estadístico de la bondad de ajuste del modelo de regresión – humedad .....	80
<b>Tabla 25</b> Pruebas de diagnóstico para supuestos de regresión para humedad. ....	84
<b>Tabla 26</b> Selección y validación del mejor modelo para humedad. ....	84
<b>Tabla 27</b> Ecuaciones planteadas para determinación de humedad.....	85

## ÍNDICE DE FIGURAS

<b>Figura. 1</b> Planta de balsa de 5 meses de edad.....	8
<b>Figura. 2</b> Dron eBee classic.....	10
<b>Figura. 3</b> Cámara S.O.D.A .....	10
<b>Figura. 4</b> Cámara Parrot Sequoia .....	11
<b>Figura. 5</b> Cámara thermoMAP senseFly .....	12
<b>Figura. 6</b> Interfaz del programa eMotion 3.5 .....	16
<b>Figura. 7</b> Gráfico de la distribución de los residuos.....	24
<b>Figura. 8</b> Gráfica de escala- ubicación .....	24
<b>Figura. 9</b> Grafico de normalidad (Q-Q plot) .....	25
<b>Figura. 10</b> Grafica de distancia Cook sin valores influyentes .....	25
<b>Figura. 12</b> Ubicación geográfica del área 1 de estudio .....	30
<b>Figura. 13</b> Ubicación geográfica del área 2 de estudio .....	31
<b>Figura. 14</b> De arriba hacia abajo planificación de vuelo para el área 1 y 2 con la cámara Parrot sequoia .....	33
<b>Figura. 14</b> De izquierda a derecha toma de muestra de suelo y lanzamiento del dron eBee- área 2 .....	36
<b>Figura. 15</b> Determinación de pH .....	39
<b>Figura. 16</b> Análisis de fósforo en laboratorio.....	42
<b>Figura. 17</b> Raster de temperatura para el área 1 de estudio.....	43

<b>Figura. 18</b>	Generación de un orto mosaico para el área 1 de estudio.....	44
<b>Figura. 19</b>	Obtención del índice de NDVI para el área 2 de estudio.....	45
<b>Figura. 20</b>	Cálculo del índice de humedad SMI para el área 1 .....	46
<b>Figura. 21</b>	Raster del índice de humedad SMI para el área 1.....	46
<b>Figura. 22</b>	Cálculo del índice de NDRE para el área 1 .....	47
<b>Figura. 23</b>	Raster del índice de NDRE para el área 1 .....	47
<b>Figura. 24</b>	Cálculo del índice GNDVI para el área 2 .....	48
<b>Figura. 25</b>	Raster del índice de GNDVI para el área 2 .....	48
<b>Figura. 26</b>	Cálculo del índice de agua NDWI para el área 1 .....	49
<b>Figura. 27</b>	Raster del índice de agua NDWI para el área.....	49
<b>Figura. 28</b>	Porción de código para la obtención de la regresión y pruebas.....	51
<b>Figura. 29</b>	Diagrama de proceso de la investigación .....	54
<b>Figura. 30</b>	Cálculo de la correlación de las variables en relación al NT.....	58
<b>Figura. 31</b>	Cálculo de la correlación de las variables en relación a la MO .....	58
<b>Figura. 32</b>	Cálculo de la correlación de las variables en relación al P.....	59
<b>Figura. 33</b>	Cálculo de la correlación de las variables en relación a la humedad. 59	
<b>Figura. 34</b>	Parcelas de diagnóstico aplicadas a la regresión de N con respecto a NDVI.....	62
<b>Figura. 35</b>	Parcelas de diagnóstico para linealidad para N.....	63
<b>Figura. 36</b>	Gráficas Cook aplicadas a la regresión de N. ....	64
<b>Figura. 37</b>	De izquierda a derecha: grafico de predicción de N con respecto al GNDVI y grafico de N conocido y simulado.....	66
<b>Figura. 38</b>	De izquierda a derecha: grafico de predicción de N con respecto a NDRE y grafico de N conocido y simulado.....	67

<b>Figura. 39</b> De izquierda a derecha: grafico de predicción de N con respecto al NDVI y grafico de N conocido y simulado .....	67
<b>Figura. 40</b> Parcelas de diagnóstico de linealidad aplicadas a MO. ....	70
<b>Figura. 41</b> Parcelas Cook para análisis de valores atípicos para MO. ....	71
<b>Figura. 42</b> Gráficos de predicción de Materia Orgánica vs NDRE.....	73
<b>Figura. 43</b> Parcelas de linealidad de supuestos para MRL de P.....	76
<b>Figura. 44</b> Parcelas de puntos influentes del modelo de regresión para P. ....	77
<b>Figura. 45</b> Gráficos de predicción de P vs NDVI. ....	79
<b>Figura. 46</b> Gráficas de linealidad para los modelos de estudio para humedad ..	82
<b>Figura. 47</b> Gráficas de distancia Cook para los modelos de estudio para la humedad.....	83
<b>Figura. 48</b> De izquierda a derecha: grafico de predicción de humedad con respecto al SMI y grafico de humedad conocida y simulada.....	85
<b>Figura. 49</b> Mapa de estimación de nitrógeno total MRL-GNDVI-A1 .....	87
<b>Figura. 50</b> Mapa de estimación de nitrógeno total MRL-GNDVI-A2.....	88
<b>Figura. 51</b> Mapa de estimación de materia orgánica MRL-NDRE-A1 .....	89
<b>Figura. 52</b> Mapa de estimación de materia orgánica MRL-NDRE-A2.....	90
<b>Figura. 53</b> Mapa de estimación de contenido de fósforo MRL-NDVI-A1 .....	91
<b>Figura. 54</b> Mapa de estimación de contenido de fósforo MRL-NDVI-A2 .....	92
<b>Figura. 55</b> Mapa de estimación de humedad MRL-SMI-A1 .....	93
<b>Figura. 56</b> Mapa de estimación de humedad MRL-SMI-A2 .....	94

## RESUMEN

El empleo de sensores remotos para estimar parámetros de calidad del suelo, ha demostrado ser una herramienta eficaz, de ahorro de recursos de análisis y estimación del rendimiento de terrenos agrícolas. Esta investigación pretende analizar por medio de índice ambientales, el comportamiento de parámetros como N, P, MO y humedad, para evaluar anomalías y alteraciones del suelo, en zonas costeras del Ecuador.

Se han generado varios modelos de regresión lineal, empleando diferentes índices espectrales, entre ellos el índices de vegetación el NDVI (Índice de vegetación de diferencia normalizada), el GNDVI (Índice de vegetación de diferencia normalizada verde) y el NDRE (Índice de diferencia normalizada de borde rojo); con la finalidad de estimar el estrés hídrico del suelo se empleó el NDWI (Índice de agua normalizado) y el SMI (Índice de humedad del suelo); de estos el que mayor correlación presentó con el N es el GNDVI con un  $R^2 = 0.7958$ , y un RSE (Error estándar residual) de 0.03664, seguido del NDRE ( $R^2=0.7578$ ), también se relacionó con el factor MO ( $R^2 = 0.5425$ , RSE 0.5975), el NDVI obtuvo mayor relación con el fósforo ( $R^2 = 0.6782$ , RSE 0.9983), finalmente el SMI obtuvo una mejor asociación con la humedad ( $R^2 = 0.7433$ , RSE 2.457) continuo el NDWI que se relaciona por determinar el contenido de agua de los cultivos.

Se concluye que las variables empleadas están estrechamente sujetas a los requerimientos nutricionales del suelo donde un exceso o déficit de estos puede desestabilizar la estructura del suelo.

**Palabras clave:** calidad de suelo, índices espectrales, UAV, nitrógeno.

## ABSTRACT

The implementation of remote sensors to estimate the parameters of the quality of the soil has demonstrated to be an efficient tool to protect the soil and the prediction of fertile soil. This investigation's analysis is done through the use of environmental indicators, the behavior of parameters such as N, P, MO and humidity, in order to evaluate changes and alterations of soil in the Coastal regions of Ecuador.

Various linear regression models have been generated using spectral indices, among them three indices of vegetation the first of normalized difference (NDVI) and the second of normalized green difference (GNDVI), and the last one known as index normalized difference red edge (NDRE); in order to estimate the water stress of the soil, the standardized water index (NDWI) and the soil moisture index (SMI), where the one with greatest correlation with N is the GNDVI  $R^2 = 0.7958$ , residual standard error (RSE) 0.03664, according to the NDRE ( $R^2=0.7578$ ), which is associated to the MO factor ( $R^2 = 0.5425$ , RSE 0.5975), the NDVI attained a stronger relationship with the phosphorus ( $R^2 = 0.6782$ , RSE 0.9983) in comparison to other parameters. Finally, the SMI had a better association with humidity ( $R^2 = 0.7433$ , RSE 2.457) continued the NDWI is compared in order to determine the cultivation's water content.

In conclusion, the variables implemented are comparable to the nutritional requirements of the soil where an excess or deficit of one of these can destabilize the structure of the soil.

**Key Works:** quality of the soil, spectral indicators, UAV, nitrogen.



## 1. INTRODUCCIÓN

El suelo es un medio de sustento para el desarrollo de plantas y organismos vivos, y el recurso principal dentro de la actividad agrícola (Strawn, Bohn, & O'Connor, 2015). El uso desmedido del mismo por parte de este sector productivo ha provocado en las últimas décadas alteraciones y contaminación que se puede presentar de forma lenta o abrupta; causando pérdidas o daños en sus propiedades físicas, químicas y biológicas (calidad del suelo); de tal forma que este tipo de anomalías influye en su capacidad natural de auto regeneración, lo que puede alterar la flora y la fauna del sitio, generar una producción deficiente y causar problemas de salud pública (Bini, 2010).

La calidad de suelo viene dada por indicadores químicos como N, P y MO, el primero es un nutriente esencial en cultivos y su absorción adecuada genera altos rendimientos (H. Wang, Mortensen, Mao, Boelt, & Gislum, 2019), el segundo es un indicador de crecimiento de plantas (Strawn et al., 2015), el último determina el comportamiento del ciclo del carbono a su vez optimiza el crecimiento de laboreos y determinar el estado de la vegetación por estar estrechamente relacionados a su adecuado desarrollo (Franzmeier, McFee, & Helmut, 2016), finalmente la humedad, un indicador físico que determina el contenido de agua y es la base de las reacciones químicas que se presenta en el suelo (M. Wang et al., 2012).

Con el transcurso del tiempo, el desarrollo tecnológico e implantación de la agricultura de precisión, la misma que ha tomado un gran interés por la degradación y pérdida de suelo (Y. Wang et al., 2016), por medio de la implementación de vehículos aéreos no tripulados (UAV) se ha logrado evaluar la salud y alteraciones

del suelo a través de la combinación de índices espectrales y modelaciones matemáticas.

El modelo de regresión lineal simple (MRLS) facilita identificar el comportamiento entre una variable regresiva y predictiva (Montgomery, Peck, & Vining, 2012), los cuales han sido obtenidos a partir de sensores remotos y parámetros del suelo.

El GNDVI permite con éxito el diagnóstico de nitrógeno en cultivos de edad media ya que emplea la banda verde e infrarrojo cercano en su cálculo, dando así una alta sensibilidad fotosintética; el NDVI demuestra su idoneidad ante la obtención de fósforo y nitrógeno (Y. Wang et al., 2016) & (Gandhi, Parthiban, Thummalu, & Christy, 2015). La humedad se encuentra relacionado al índice SMI ayudando así a la determinación del estrés hídrico (Saha, Patil, Goyal, & Rathore, 2018). Además el índice NDRE al emplear su banda de borde rojo que captura una parte sensible del espectro de los cultivos lo que nos ayuda a determinar de forma temprana la presencia de anomalías en el suelo gracias a la relación C/N (Rodríguez, Fitzgerald, Belford, & Christensen, 2006).

De tal manera que el objetivo de este trabajo fue generar varios modelos matemáticos que permitan estimar la salud del suelo en zonas costeras del Ecuador; esto se realizó a través del estudio de parámetros de calidad e índices de reflectancia multiespectral para dos áreas de plantaciones de balsa ubicadas en el sector de Valencia provincia de Los Ríos.

## **2. OBJETIVOS**

### **2.1. Objetivo General**

Generar varios modelos matemáticos para la estimación de la salud del suelo en áreas agrícolas de la zona costera del Ecuador por medio del análisis de parámetros de calidad del mismo e índices de reflectancia espectral, obtenidas a partir de imágenes captadas por un vehículo aéreo no tripulado.

### **2.1. Objetivos específicos**

- Obtener información georreferenciada del área de estudio a través de la recolección de datos por medio de un dron y el empleo de ArcGIS y Pix4D.
- Generar varios modelos matemáticos con la información de índices espectrales calculados para el área de estudio, empleando el software estadístico RStudio.
- Conocer por medio de la generación de mapas digitales el grado de afectación del suelo.

### **3. MARCO TEÓRICO**

#### **3.1. El suelo**

Uno de los principales recursos en los que se sustenta la vida, es el suelo el mismo que se considera una combinación compleja que envuelve agua, diferentes clases de solutos, microorganismos, plantas y sólidos ya sean orgánicos e inorgánicos (Conklin, 2013). El suelo permite el crecimiento de plantas que se convertirán en alimento ya sea de seres humanos como animales, estas forman el primer eslabón de la cadena trófica, por lo tanto, todo lo que se genera ya sea directa o indirectamente del suelo conlleva a la vida en la Tierra.

El incremento de individuos y sus necesidades inducen a cambios ineludibles en el uso del recurso que a su vez alteran a la composición química, física y biológica causando así la disminución de la calidad del mismo.

#### **3.2. Indicadores de calidad del suelo**

La Sociedad de Ciencias de Suelo de América (SSSA) asigna a la calidad del suelo como la capacidad de funcionar conforme a los límites de los ecosistemas naturales y preservar el rendimiento de los cultivos respaldando así la habitabilidad en la Tierra (Schjørring, Elmholt, & Christensen, 2004), los cuales son físicos, químicos y biológicos, estos permitirán determinar la situación y manejo actual del suelo (Bai et al., 2018).

##### **3.2.1. Indicadores físicos**

Los indicadores físicos son factores que pueden variar dependiendo de la ubicación geográfica.

### **3.2.1.1. Textura**

La textura es la proporción de diferentes tamaños de partículas que existen en el suelo, las cuales pueden ser arcilla, limo y arena; cada uno de estos influyen en la estructura y requerimientos nutricionales del suelo (Hillel, 2004).

### **3.2.1.2. Humedad**

Es el porcentaje de agua que existe en un volumen de superficie, esta propiedad está directamente relacionada al tipo de suelo, densidad aparente, tamaño de partícula, lugar geográfico, climatología, precipitaciones y temperatura (Reyna et al., 2014).

La humedad es un parámetro importante al momento de realizar estudios de suelo ya que nos permite determinar problemas que se relacionen con el estrés hídrico del suelo generando cambios en la fisiología (Reyna et al., 2014).

### **3.2.2. Indicadores químicos**

Los indicadores químicos están relacionados a las condiciones que afectan al suelo y a su vez a la planta.

#### **3.2.2.1. pH**

El pH es la concentración de  $H^+$  en un medio, se puede dividir en 3 rangos generales básico, neutro y ácido. La escala de pH oscila entre 0-14, con un pH igual a 7 consideramos neutral, inferior a 7 es ácido si es inferior a 4 corresponde a muy ácido, mientras que los que superan los 7,5 son básicos o alcalinos y si son superiores a 8 muy básicos; el rango óptimo para la producción de un cultivo oscila entre los 6.5-7.8 (Franzmeier et al., 2016).

### **3.2.2.2.Nitrógeno total**

El suelo contiene un sin número de compuestos ricos en nitrógeno los que permiten la descomposición en nitratos, para ser utilizados por la planta. Existen dos procesos para la obtención de nitrógeno orgánico, uno que parte de amoníaco para convertirse en nitrito, seguido de nitrato por medio de una oxidación en condiciones aeróbicas, húmedas y temperatura adecuada; y otra oxidación que parte desde nitrito a nitrato, el nitrito de este proceso proviene del ambiente por su volatilidad, la misma que causa grandes preocupaciones por su alta toxicidad (Conklin, 2013).

### **3.2.2.3.Fósforo**

El fósforo es un compuesto que se encuentra en el suelo gracias a procesos que han provocado el desgaste de la roca madre. La cantidad total de este nutriente se presenta en forma orgánica e inorgánica en el suelo (Navarro Garcia & Navarro Blaya, 2003).

El fósforo en el suelo se encuentra en forma de ácidos nucleicos, fosfolípidos, fitina y otros derivados, estos forman alrededor del 20% al 80% del fósforo que tiene el suelo (Navarro Garcia & Navarro Blaya, 2003). Por lo tanto solo una pequeña cantidad de fósforo que contiene el suelo es asimilable por las plantas, para que esto ocurra el fósforo debe encontrarse en forma de  $PO_4H_2^-$  o  $PO_4H^{2-}$  teniendo en cuenta el pH, el cual es encargado de regular las reacciones (Hillel, 2004).

### **3.2.2.4.Materia Orgánica**

Es un elemento esencial en el suelo, por ser un componente dinámico éstas dependen de otras características. Es un componente dependiente de un sin número de factores a los que se encuentra vinculado como la topografía del sitio, clima, tipo

de vegetación, disponibilidad de nutrientes, uso y manejo del suelo (Björklund & Mello, 2012).

La materia orgánica es proveniente de la descomposición de materiales biológicos generalmente proveniente de animales o plantas que se han descompuesto en el suelo por actividad microbiana que habita en el mismo, este proceso es lento pero la decaída es mucho más lenta (Björklund & Mello, 2012).

### **3.3.Características generales del cultivo**

La balsa es una planta originaria de América latina; se extiende desde México hasta Bolivia, en Ecuador se distribuye en la zona de la costa y la Amazonía; su nombre científico es: *Ochroma pyramidale* o también conocido como boya (Parrales, 2012).

El árbol de balsa alcanza una altura de crecimiento máximo de 30 metros, posee un diámetro que va de 30 a 90 cm; tiene un tronco alargado y cilíndrico, con una corteza externa lisa de color gris e interna color amarillenta, posee una copa amplia y redondeada de gran volumen; sus hojas son acorazonadas, simples y laminadas que se distribuyen en forma de espiral por el mismo; sus flores son grandes y de coloración blanca, además de poseer un fruto en forma de capsula de color verdoso, los cuales contienen unas semillas muy pequeñas que van desde los 500 a 800 en número (Garwood & Lightton, 1996).



**Figura. 1** Planta de balsa de 5 meses de edad

Fuente: Quintana J, Tituaña K, (2019)

### **3.3.1. Hábitat y requerimientos de desarrollo**

Este tipo de planta se desarrolla en zonas cálidas húmedas con una temperatura que oscile los 22 a 30 °C, una precipitación (mm) de 500 a 3000 y un rango altitudinal límite de 1200 m.s.n.m., cabe señalar que este tipo de cultivos crecen en lugares con un tipo de suelo franco, franco arenoso o limoso, que sea levemente ácido, con un contenido de materia orgánica mayor al 3%, y que además cuente con un buen drenaje y luminosidad, de modo que si el suelo es de tipo alcalino con un mal drenaje no se pueden desarrollar este tipo de cultivos; también cabe señalar que esta planta no soporta las heladas (Parrales, 2012).

### **3.3.2. Ciclo de desarrollo**

La balsa posee un crecimiento muy rápido; llegando a tener al año de edad una altura de 1.8 a 4.8 m, de tal manera que mensualmente se desarrolla entre 15 a 40 cm dependiendo de la planta (Garwood & Lighthton, 1996). Una vez transcurrido este tiempo puede crecer hasta 3 m de altura por año hasta que alcanza la madurez alrededor de los 6 a 10 años posterior a esto el crecimiento de esta especie decrece hasta llegar los 30 m, posee un tiempo estimado de vida promedio de 7 años, donde



el mayor rendimiento económico de la planta se da a los 5 y 6 años, por lo cual son talados para aprovechamiento de su madera (Paillacho, 2010).

### **3.4.Sensores remotos**

Es un medio por el cual se puede adquirir información de una superficie u objeto a diferentes escalas en tiempo real de forma aérea o por medio de plataformas satelitales con la finalidad de ahorrar y economizar recursos (Everaerts, 2008).

En la actualidad la aplicación de estos se ha visto reflejada en el uso de UAV al ser de fácil adquisición, eficientes y flexibles al momento de acceder a cualquier lugar (Ammour et al., 2017).

Hay que tomar en cuenta que este tipo de mecanismo miden la radiancia y la reflectancia donde el primero es la energía que emite el sensor en una dirección dada, y el segundo es la relación existente entre la energía reflejada por un objeto y la que incide en el mismo, donde el color del objeto está determinado por la longitud de onda que se emita (Finn & Reed, 2012).

#### **3.4.1. Vehículo aéreo no tripulado (UAV)**

Comúnmente conocidos como drones lo cuales son mecanismos aéreos robóticos que pueden ser autónomos, es decir que son operados por medio de un software especializado, o a través de un control remoto, estos dependiendo de su uso están equipados de varios complementos, desde cámaras de baja o alta resolución, radares, GPS y hasta sensores que pueden ser térmicos o multiespectrales (Vega, Ruíz, & Garro, 2017).

##### **3.4.1.1.Dron eBee y complementos**

Es un dron de mapeo profesional autónomo de ala fija y una hélice, echo de espuma de polipropileno, con un peso aproximado de 690 gramos, que permite

capturar distintas imágenes del lugar de estudio, con un tiempo estimado de vuelo de 50 minutos. Dependiendo de la cámara que se emplee en el dron se puede conseguir imágenes de tipo: RGB, multiespectrales o térmicas y con una autocorrección sin la necesidad de establecer puntos de control, estas pueden ser empleadas en el sector agrícola para estimar la calidad del suelo, crecimiento de los cultivos, entre otros (SenseFly, 2019).



**Figura. 2** Dron eBee classic

Fuente: SYSMAP (<https://sysmap.net/ebec-classic/>)

#### **3.4.1.1.1. Cámara S.O.D.A**

También conocida como sensor optimizado para aplicaciones de dron, es una cámara que permite obtener imágenes tipo RGB nítidas las cuales permiten crear orto mosaicos y MDS de alta calidad, pesa aproximadamente 75 gramos e incorpora un sensor de alta resolución, el cual en terreno aborda los 2.9 cm/ pixel volando a 122 metros (SenseFly, 2018).



**Figura. 3** Cámara S.O.D.A

Fuente: tecnitop (<https://tecnitop.com/es/camaras-accesorios-y-software/>)

#### **3.4.1.1.2. Cámara Parrot Sequoia**

Empleada principalmente en la agricultura de precisión, para estimar la calidad, crecimiento, vigorosidad, y vitalidad de los cultivos a través de la cantidad de absorción y reflexión de la luz, gracias a sus dos sensores que posee el primero de uso solar y el segundo multiespectral, los cuales simultáneamente captan imágenes en cuatro bandas especiales (verde, roja, infrarrojo cercano y borde rojo), permitiendo apreciar el espectro electromagnético de la luz, es decir lo que es visible y no al ojo humano (Parrot SA., 2019); del mismo modo posee un GPS para incrementar la precisión de los datos a estimar en campo, igualmente incluye una cámara RGB de 16 mega pixeles para la creación de orto mosaicos del área de estudio e incluye una tabla de calibración o diana (Sequoia, 2016).



**Figura. 4** Cámara Parrot Sequoia

Fuente: senseFly([https://tycgis.com/parrot\\_sequoia/](https://tycgis.com/parrot_sequoia/))

##### **3.4.1.1.2.1.Sensor multiespectral**

La cámara Parrot sequoia posee este sensor, el cual capta la información específica del espectro electromagnético por medio de 4 bandas: roja (660 nm), verde (550 nm), borde rojo (735 nm) e infrarrojo cercano (NIR) (790 nm), las cuales son empleadas como se mencionó anteriormente para estimar la calidad y vitalidad de los cultivos y la productividad del suelo. Por consiguiente, la banda roja es empleada para determinar zonas de suelo desnudo, cuerpos de agua o infraestructuras, la banda verde y NIR para estimar la vegetación, y la de borde rojo

se emplea para determinar los principios de estrés de las plantas (Paredes, Gonzalez, Saito, & Flores, 2017).

#### **3.4.1.1.3. Cámara thermoMAP**

Este tipo de cámara posee un sensor infrarrojo térmico, que permite valorar en la agricultura de precisión el estrés hídrico de los cultivos por medio de la relación entre la proporción de agua que absorbe la planta y la temperatura existente en las hojas de la misma (Conapa, 2017). Este dispositivo tiene un peso aproximado de 132 gramos, su lente puede captar temperaturas que abordan los -40 °C a 160 °C; además durante el vuelo posee una calibración automática de temperatura y alcanza los 14 cm/pixel a 75 metros de altura (SYSMAP, 2017).



**Figura. 5** Cámara thermoMAP senseFly

Fuente: Tecnitop (<https://tecnitop.com/es/camaras-accesorios-y-software/>)

### **3.5. Índices espectrales**

Entre las técnicas de uso de información satelital multiespectral encontramos los índices espectrales, los cuales están compuestos por operaciones algebraicas efectuadas sobre los valores numéricos de los píxeles utilizando dos o más bandas; generalmente esta información es obtenida a partir de satélites o vehículos aéreos no tripulados (Muños Aguayo, 2013).

Dentro de estos índices encontramos los de vegetación, suelo, agua, clorofila y los de borde rojo; cabe mencionar que estos índices son adimensionales.

### **3.5.1. NDVI**

Este índice pertenece a los de vegetación y es uno de los más relevantes en la agricultura por su sencillez, su nombre completo es Índice Normalizado Diferencial de Vegetación (NDVI) el cual nos permite obtener características de un cultivo a partir de la reflectancia en el rojo y la longitud de onda en el infrarrojo cercano (Gandhi et al., 2015).

Este índice está dado por la siguiente fórmula:

$$NDVI = \frac{NIR - BR}{NIR + BR}$$

Donde NIR es del dato de la banda de infrarrojo cercano y BR banda roja (Muños Aguayo, 2013). El NDVI es utilizado para determinar la fracción fotosintética activa que absorbe la vegetación, por lo mismo se encuentra directamente relacionado a la fenología, estado y nutrientes de la vegetación (Alcaraz, 2014). Este índice va desde un rango de -1 a 1, donde si es 0 o valores negativos, significa que no hay presencia de vegetación (Muños Aguayo, 2013).

### **3.5.2. SMI (Soil moisture index)**

Este índice permite determinar la humedad del suelo a través de la correlación del NDVI y la temperatura de superficie (LTS) empleando la siguiente ecuación:

$$SMI = \frac{LST_{max} - LST}{LST_{max} - LST_{min}}$$

Donde el  $LST_{max}$  y  $LST_{min}$  son la temperatura máxima y mínima para un NDVI dado. Su rango de variación es de 0 a 1 donde los valores cercanos a uno representa

baja infiltración, menor presencia de cobertura vegetal y temperatura superficial del suelo lo que beneficia a un mayor contenido de humedad y cero indica a zonas con mayor vegetación, temperatura superficial, mayor infiltración y baja humedad (Saha et al., 2018).

### **3.5.3. NDRE**

Conocido como índice de diferencia normalizada de borde rojo, a diferencia del NDVI emplea la banda de borde rojo, la cual es más sensible al contenido de clorofila en la hoja gracias al aumento de reflectancia en su longitud de onda que oscila los 720 nm de ancho de banda (Barnes, Clarke, Richards, & Colaizzi, 2000), lo que le permite realizar mediciones más profundas en el dosel a contraste de la banda roja que posee una reflectancia de 670 nm, y no asimila más allá de las primeras capas del mismo (Rodríguez et al., 2006).

El cálculo de este índice se lo da a través de la siguiente ecuación:

$$NDRE = \frac{NIR - Red\_edge}{NIR + Red\_edge}$$

Posee un rango de variación de -1 a 1 los cuales permite determinar facialmente la cantidad de nitrógeno, clorofila y estado de salud de los cultivos, de preferencia de mediano y avanzado crecimiento (Xie et al., 2018).

### **3.5.4. GNDVI**

Uno de los índices que se usan con mayor frecuencia para realizar investigación sobre la agricultura es el índice de vegetación normalizada verde (GNDVI), el mismo que nos aporta información acerca de la actividad fotosintética de la planta, pudiendo establecer así, parámetros como el consumo de agua y la cantidad de nitrógeno de la vegetación (Kharuf, Orozco, Díaz, & Pineda, 2018).

Este índice se calcula a partir de dos bandas de pixel el infrarrojo cercano (NIR) y verde (GREEN), determinado por la siguiente formula:

$$GNDVI = \frac{NIR - B_{Green}}{NIR + B_{Green}}$$

Cabe mencionar que este índice es considerado para vegetación elevada por su gran sensibilidad en este tipo de cultivos, donde los resultados van de -1 a 1; los valores negativos se consideran cuerpos de agua o suelo descubierto.

### **3.5.5. NDWI**

El índice de agua normalizado (NDWI) es un índice sensible a la variación de contenido de agua en la vegetación permitiendo así determinar el estrés hídrico del suelo, saturación de humedad, cantidad de agua de la vegetación o delimitar cuerpos de agua, este utiliza las bandas inversas a las del índice diferencial normalizado de vegetación (NDVI), realzando así cuerpos de agua (Xu, 2006). Los valores obtenidos van de -1 a 1 siendo el agua valores positivos y vegetación suelo o rocas valores cero o negativos (Ariza Ortiz, Roa Melgarejo, Serrato, & León Rincón, 2018).

Este índice esta definitivo por las siguiente formula:

$$NDWI = \frac{B_{Green} - NIR}{B_{Green} + NIR}$$


## **3.6. Softwares empleados**

Los programas que se emplearon para el desarrollo de este trabajo se detallan a continuación en los siguientes apartados.

### **3.6.1. eMotion 3.5.0**

Es un software especializado, utilizado para planificar, monitorear y procesar el vuelo del dron eBee; donde en la planificación se emplean uno o varios bloques de

misiones los cuales permiten crear diferentes tipos de vuelo que van desde un mapeo horizontal, mismo en el que se establece las líneas de vuelo y puntos de referencia; hasta la creación de una ruta personalizada alrededor de distintos puntos de interés (senseFly, 2018). El monitoreo del vuelo del dron se realiza de manera directa con el programa; el cual muestra diferentes parámetros como son la velocidad del viento, temperatura del dron y ambiente, distancia recorrida, entre otros los cuales facilitan la operación del equipo en campo (senseFly, 2018). Este programa también se lo emplea para el procesamiento de datos de vuelo del dron.



**Figura. 6** Interfaz del programa eMotion 3.5

Fuente: Tecnitop ( <https://tecnitop.com/es/emotion-sensefly/> )

### 3.6.2. Pix4D

Es un programa especializado empleado para el procesamiento de imágenes multiespectrales, térmicas y RGB, con el fin de poder crear campos de entrada como son orto mosaicos; modelos digitales de superficie (DMS), nubes de puntos, etc; los mismos que pueden ser aprovechados para el análisis espacial por medio de programas como ArcGIS. Este proceso se da a través del emparejamiento de imágenes con un buen solape longitudinal y mismos puntos característicos que permite crear diferentes campos de entrada (Pix4D, 2019). Otra función importante de este programa es que permite obtener mediciones de distancias, áreas, volúmenes, y la generación de curvas de nivel, etc.



### **3.6.3. ArcGIS**

Es una familia de programas perteneciente a la empresa ESRI , que son aplicados dentro de los SIG (Sistemas de Información Geográfica), los cuales son un conjunto de técnicas de análisis, almacenamiento, monitoreo y gestión de datos geoespaciales, que permiten generar información del mundo real para la toma de decisiones específicas (Rosete & Bocco, 2009).

ArcGIS proporciona un sistema para trabajar con datos geográficos, por medio de la creación, manejo, almacenamiento, análisis y la visualización de los mismos (Escolano, 2015).

### **3.6.4. Rstudio**

Es un software estadístico libre y de código abierto con un lenguaje de programación script, posee una amplia gama de herramientas conocidas como librerías que permiten realizar diferentes análisis, cálculos, representaciones gráficas y la generación de modelos con los datos proporcionados por el usuario (Garrett & Hadley, 2017).

#### **3.6.4.1. Paquete “caret”**

El paquete “caret” que significa *Classification and Regression Training* es una agrupación de diferentes funciones que pretenden crear modelos predictivos por medio de la separación y procesamiento de datos, selección e importancias de variables, ajuste de modelos por remuestreo entre otras actividades (Zelad, 2017).

#### **3.6.4.2. Paquete “Corrplot”**

El paquete “corrplot” nos permite realizar una visualización grafica de una matriz de correlación, intervalos de confianza o matrices de manera general, esta también dispuesto por algoritmos que reordena las matrices empleadas (Taiyun Wei et al.,

2017). A demás esta librería nos permite aplicar detalles en las gráficas como formas, colores, textos, etiquetas.

#### **3.6.4.3.Paquete “Car”**

El paquete “car” contiene funciones que se pueden emplear en modelos lineales, estandarizados, y análisis de regresiones los cuales pueden ser diagnosticados mediante gráficos (Fox, 2002).

#### **3.6.4.4.Paquete “Tidyverse”**

Contiene un conjunto de potentes paquetes para análisis, categorización, y visualización de datos. Algunos de los paquetes que se encuentran dentro de tidyverse son el ggplot2 que permite el diseño y visualización de gráficos estéticos y el dplyr que permite la adecuada manipulación de la información, la agrupación de todas estas librerías permiten realizar un adecuado modelamiento estadístico (Stanley, 2017).

#### **3.6.4.5.Paquete “GGally”**

Este paquete se basa en el diseño de la gramática de gráficos, lo cual permite reducir la complejidad de elaboración de los mismo, con esta librería se puede crear desde matrices gráficas, hasta emplear diversas funciones para trazar redes (Schloerke B, 2017). Es una extensión del paquete ggplot2.

#### **3.6.4.6.Paquete “lmtest”**

Contiene un conjunto de pruebas para el análisis y validación de regresiones lineales, además provee diferentes herramientas para la deducción de modelos paramétricos, mismo que contienen una o varias variables (Torsten & Achim, 2019).

### **3.7.Modelo de regresión lineal**

#### **3.7.1. Análisis de correlación**

Para la determinación de un modelo matemático se debe realizar una exploración de datos que permita determinar la correlación existente entre una variable dependiente y otra independiente, para ello es posible realizar esta observación por medio de un diagrama de dispersión.

##### **3.7.1.1. Diagramas de dispersión**

Los diagramas de dispersión ayudan a interpretar la relación entre dos variables asociadas que aparecen en pares (x, y), se dibuja como una relación de nube de puntos y se interpreta mediante su forma (Pardo Merino & Ruiz Díaz, 2001).

##### **3.7.1.2. Coeficiente de correlación lineal**

Es la cuantificación existente entre la relación de dos variables y permite establecer el grado de linealidad entre x e y, existen dos coeficientes el de Pearson y Spearman, siendo el paramétrico el de Pearson el mismo que evalúa la correlación lineal entre parámetros cuantitativos, mientras que el segundo cuantifica cualquier tipo de asociación (Laguna, 2009).

##### **3.7.1.3. Coeficiente de correlación de Pearson**

Estimador muestral para la asociación entre dos variables x e y, este mide si los puntos tienen una tendencia de disposición lineal, toma valores entre -1 y 1. Es denominado paramétrico por utilizar valores de media, varianza, etc. (Pardo Merino & Ruiz Díaz, 2001). Por lo cual para obtener valores razonables del coeficiente se requiere criterios de normalidad entre las variables.

### 3.7.2. Modelo de regresión lineal simple (MRLS)

Tiene como finalidad interpretar el comportamiento de una variable predictiva o dependiente ( $Y$ ) a partir de una variable regresiva o independiente ( $X$ ) (Laguna, 2009).

El MRLS está dado por la siguiente ecuación:

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

Donde se confirma la influencia de un dato sobre el parámetro dependiente ( $Y$ ) y se generan dos grupos, uno que explica el comportamiento de la variable independiente ( $X$ ) y otro que encierra factores denominados errores aleatorios ( $\varepsilon$ ), lo que hace que la dependencia entre la variable dependiente e independiente esté sujeta a incertidumbre (Montgomery et al., 2012)

#### 3.7.2.1. Método de mínimos cuadrados

Es uno de los métodos que nos permiten obtener los parámetros desconocidos  $\beta_0$  y  $\beta_1$  de modo que la solución nos de la menor suma posible de desviaciones cuadradas de los datos de muestreo observados (Novales, 2010). Por lo tanto, el objetivo de este método es la elección de  $\beta_0$  y  $\beta_1$  minimizando la suma que poseen los cuadrados de los residuos.

##### 3.7.2.1.1. Fuentes de variación de regresión lineal

La desviación total de una regresión ( $Y_i$ ) está dada por la suma de todas las desviaciones, por lo que se tiene que:

$$\sum (y_i - \bar{y})^2 = \sum (\bar{y}_i - \bar{y})^2 + \sum (y_i - \bar{y}_i)^2$$

Donde:

$\sum (y_i - \bar{y})^2$  Es la suma de cuadrados total

$\sum(\bar{y}_i - \bar{y})^2$  Es la suma de cuadrados de regresión

$\sum(y_i - \bar{y}_i)^2$  Es la suma de cuadrados residuales

#### *1.1.1. Suma cuadrática total*

Permite la medición de la variación total en los datos de Y, se utiliza para realizar el cálculo de varianza de la muestra estudiada.

#### *1.1.2. Suma cuadrática de regresión*

Mide la variación de los valores experimentales de la variable dependiente, teniendo en cuenta la relación lineal que hay entre las variables estudiadas.

#### *1.1.3. Suma cuadrática de error*

Cuantifica la dispersión de información observada de la variable dependiente (Y) con respecto a la recta de regresión.

### **3.8.2.2. Coeficiente de determinación $R^2$**

Es un estadístico que representa la proporción de variación entre variables del modelo, este coeficiente se encuentra relacionado al error por lo que, cuanto menor sea este mejor bondad de ajuste tendrá (Rawlings, Pantula, & Dickey, 1998).

Está determinado por la siguiente ecuación:

$$r^2 = 1 - \frac{S_e^2}{S_y^2}$$

Donde:

$r^2$ =Valor adimensional que va de 0 a 1, dando como mejor ajuste valores cercanos a 1.

### 3.8.2.3. $R^2$ ajustado

El coeficiente de determinación ajustado el cual se representa por  $R^2_{adj}$ . está estrechamente relacionado al coeficiente de terminación  $R^2$ . El  $R^2_{adj}$ . es una reescala del coeficiente de determinación, de modo que en este caso implica una proporción de cuadrados medios en vez de una de suma de cuadrados (Rawlings et al., 1998).

$$R^2_{adj} = 1 - \frac{(1 - R^2)(n - 1)}{(n - p')} = 1 - \frac{MS(Res)}{MS(Total)}$$

Donde:

$MS(Res)$ : Cuadrado medio residual. (Influenciado por  $R^2$  y número de datos)

$MS(Total)$ : Cuadrado medio total (Influenciado por P value y número de datos)

Este parámetro no se ve afectado por el número de variables del modelo, se ajusta en algún límite superior conforme se añadan las variables, puede ser positivo o negativo este signo nos informa la dirección de la recta, pero lleva la misma conclusión que el coeficiente determinación; el más alto determinará mejor correlación (Laguna, 2009).

### 3.8.2.4. Desviación típica o estándar

Es la valoración de dispersión de las variables sobre su media, por lo que nos permite conocer el número de valores que se encuentran cerca a la media suponiendo que los datos tengan una distribución normal (Perez, 2015).

### **3.8.2.5. Error estándar residual (RSE)**

El error estándar es una medida de determinación de confianza, por lo que este depende de la desviación estándar y del número de datos, viene representado por el valor de la desviación estándar dividido para la raíz cuadrada del tamaño de muestras, este valor va disminuyendo según va aumentando el número de muestras y a su vez disminuye la variabilidad de la probabilidad (Altman & Bland, 2005).

### **3.7.3. Supuestos del modelo**

Tomando en cuenta el MRL y con la finalidad de realizar un análisis y validación precisa, se tiene que cumplir cuatro supuestos.

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$$

Donde  $\beta_0$  y  $\beta_1$  son los coeficientes de la regresión lineal y  $\varepsilon_i$  es el error residual de la ecuación.

1. Debe existir linealidad entre los parámetros  $Y_i$  y  $X_i$  (Szretter, 2017).
2. Los residuos ( $\varepsilon_i$ ) deben estar normalmente distribuidos.
3. Los  $\varepsilon_i$  deben tener homoscedasticidad, es decir los residuos deben tener homogeneidad en la varianza (Kassambara, 2018b).
4. Debe existir independencia entre los residuos y no existir una correlación con  $X_i$  (Szretter, 2017).


### **3.7.4. Diagnóstico del modelo MRL**

Una vez realizado el análisis de los resultados de la regresión lineal se debe efectuar un diagnóstico mediante el estudio de los errores residuales para verificar si el modelo funciona adecuadamente con los datos proporcionados y a su vez confirmar si se validan o no los supuestos de la regresión, con la finalidad de evitar

valores atípicos o posibles conflictos que pueden afectar al modelo. Esto se lo puede efectuar mediante diversas formas como son gráficos de diagnóstico o pruebas.

#### 3.7.4.1. Gráfica de residuos vs ajustados

Según (Madariaga, González, & Rodríguez, 2013) sirve para identificar la linealidad de la distribución donde los valores residuales se representan en forma de nube de puntos.




**Figura. 7** Gráfico de la distribución de los residuos.

Fuente: stdha ( <http://www.sthda.com/english/articles/39-regression-model-diagnostics/>)

#### 3.7.4.2. Gráfica de escala- ubicación

Es una gráfica que comprueba la homogeneidad en la varianza los residuos; la cual recibe el nombre de homocedasticidad. La propagación lineal de la nube de puntos es un buen indicador de homocedasticidad si se distribuyen de manera igual, caso contrario nos indica que existe heteroscedasticidad (Kassambara, 2018b).




**Figura. 8** Gráfica de escala- ubicación



Fuente: stdha ( <http://www.sthda.com/english/articles/39-regression-model-diagnostics/>)

### 3.7.4.3. Gráfica de normalidad (Q-Q plot)

Es un método gráfico que permite apreciar o comparar que tan cerca están los datos dentro de una distribución normal, para lo cual analiza cómo están distribuidos los residuos estandarizados sobre la diagonal a 45 grados del gráfico, de tal manera que si estos no se alinean sobre la recta se descarta la normalidad y puede existir una desviación hacia la izquierda o derecha (Bouza-Herrera, 2018).




**Figura. 9** Grafico de normalidad (Q-Q plot)

Fuente: Modelos de regresión y sus aplicaciones(Bouza-Herrera, 2018)

### 3.7.4.4. Gráfica de distancia Cook

Este tipo de gráfico indica como intervienen los valores observados dentro de los resultados de la regresión, en el caso de que estos sean cercanos a uno o lo sobrepasen, son conocidos como valores atípicos o influyentes y deben ser tomados en cuenta y analizados ya que pueden actuar considerablemente dentro del modelo (SPH, 2016).



**Figura. 10** Grafica de distancia Cook sin valores influyentes

Fuente: stdha ( <http://www.sthda.com/english/articles/39-regression-model-diagnostics/>)

### 3.7.5. Prueba de Durbin Watson

Este test analiza la independencia de los residuos, utiliza dos hipótesis, una nula que evalúa la no auto correlación y una alternativa que valora la dependencia de los mismos, emplea un estadístico conocido como  $d$  que va de cero a cuatro donde valores cercanos a cero señala una auto correlación positiva, valores próximos a 2 no poseen auto correlación y valores cercanos a 4 indica auto correlación negativa, cabe mencionar que la mayoría de los problemas de regresión presentan una auto correlación positiva (Montgomery et al., 2012).

**Tabla 1** Regla de decisión para la prueba Durbin Watson

Rango	Diagnostico
$d = 2$	No existe auto correlación
$1.5 \leq d \leq 2.5$	Aceptable
$d < 1.5$	Existe auto correlación positiva
$d > 2.5$	Existe auto correlación negativa

Elaborado por: Quintana J, Tituaña K, (2019)  
Fuente: (Bouza-Herrera, 2018)

### 3.7.6. Prueba Shapiro Wilk

Este tipo de prueba es aplicable para muestras inferiores a 50 datos; ayuda a determinar desviaciones en la normalidad del modelo, la prueba acepta la hipótesis de la normalidad si el p value es mayor a 0.05 y rechaza el mismo si es inferior a este; en el caso de que el modelo no pase la prueba se puede establecer que los datos no se ajustan a una distribución normal con el 95% de confianza (Seir, 2002).

### 3.7.7. Prueba de contraste Breusch-Pagan

Esta prueba se emplea para evaluar la desigualdad de varianza de los residuos lo que permite determinar la heteroscedasticidad de los mismos, la prueba rechaza la hipótesis de diferente varianza si el p value es superior a 0.05, esta prueba es muy sensible a los cambios de la normalidad (Williams, 2015).

### 3.7.8. Criterio de información Akaike

Este tipo de criterio ayuda a seleccionar el mejor modelo por medio de su capacidad predictiva y la cantidad de parámetros a considerarse para su mejor ajuste, si se tiene una menor cantidad de estos el ajuste es mejor; para la selección del criterio AIC se debe escoger el de menor valor posible (Paladino, 2017).

### 3.7.9. Métricas de rendimiento del modelo

Con la finalidad de evaluar el rendimiento del modelo para predecir el resultado de nuevas observaciones se emplean diversas variables métricas que incluyen al R cuadrado ( $R^2$ ), al error cuadrático medio (RMSE) y al error cuadrático absoluto (MAE), los cuales indican la eficiencia de la regresión durante una validación cruzada (Kassambara, 2018a).

**R cuadrado:** representa el valor de correlación cuadrática entre las variables medidas y las simuladas, mientras más alto sea este valor mejor será el ajuste.

**Error cuadrático medio (RMSE):** mide el error de predicción de una observación, por medio de la diferencia promedio de los resultados conocidos y los predichos, cuando más bajo sea este mejor es el modelo (Swalin, 2018).

**Error cuadrático absoluto (MAE):** es más sensible a los valores atípicos, y es la diferencia absoluta entre los valores predichos y el observado, mientras más bajo sea el MAE mejor será el modelo.

### 3.7.10. Validación cruzada K-Fold

Permite evaluar el rendimiento normal y predictivo del modelo, además de ayudar a saber cómo funcionará el mismo con un conjunto de datos independientes, a través de la subdivisión de la información conocido como datos de entrenamiento y por medio del cálculo del error de predicción (Kassambara, 2018a).

Esta subdivisión contiene un único parámetro denominado  $k$  que consiste en el número de subgrupos que se dividirá el modelo los cuales deben ser aproximadamente del mismo tamaño, donde la primera subdivisión será el conjunto de validación y será ajustado a los  $k-1$  restantes; el  $k$  recomendado para evitar sesgos y varianzas muy altas es del 5 o 10, aunque este último es el más utilizado dentro del campo investigativo (James, Witten, Hastie, & Tibshirani, 2013).


#### **3.7.11. Predicción de los modelos de regresión**

Los intervalos de predicción están representados por una nube de puntos donde la interpretación es igual al análisis del diagrama de dispersión, el mismo que debe poseer una distribución lineal (Spence & Stanley, 2016).

## 4. METODOLOGÍA

### 4.1. Descripción de las zonas de estudio


La investigación realizada se llevó a cabo en dos zonas de cultivo de balsa pertenecientes a la empresa Plantabal S.A. ubicadas en Ecuador, provincia de los Ríos, cantón Valencia, cerca del recinto de Los Vergeles.



**Figura.** Ubicación geográfica de las áreas de estudio  
Elaborado por: Quintana J, Tituñña K, (2019)

#### 4.1.1. Primera área de estudio

El primer sitio de estudio denominado área 1 pertenece a las plantaciones de PR02 del año 2018, está localizado entre los recintos de San Alfonso y Maldonado, los cuales se encuentran ubicados al sur este de la parroquia rural de Los Vergeles; cuenta con una extensión de 10.88 hectáreas, y posee un cultivo de balsa de 6 meses en promedio; esta zona está ubicada a un rango altitudinal de 130 a 162 m.s.n.m.



**Figura. 11** Ubicación geográfica del área 1 de estudio

Elaborado por: Quintana J, Tituaña K, (2019)


El clima existente en la zona es tropical mega térmico semi húmedo según la clasificación climática de Thornthwaite, esta se caracteriza por presentar una estación lluviosa y una seca que va alrededor de 8 a 11 meses; la temperatura promedio del lugar varía entre 25 y 26 °C, posee precipitaciones que oscilan los 2700 a 2800 mm, y una humedad que varía entre los 60 y 85% dependiendo del mes en que se encuentre (PLANTABAL S.A., 2015).

El suelo del área de estudio se caracteriza por ser poco profundo, cuenta con una textura equilibrada predominando los suelos de tipo franco y sus combinaciones (franco arenoso, franco arcilloso, franco limoso), posee una pendiente de 5-12%, un pH ligeramente ácido, además de caracterizarse por ser un suelo no salino, y presentar un drenaje bueno o moderado (PLANTABAL S.A., 2015).

#### **4.1.2. Segunda área de estudio**

Denominada para esta investigación como área 2, pertenece a las plantaciones FuturaCorp 06 (FC06) del año 2017, cuenta con una superficie de 23.18 hectáreas,

las cuales poseen cultivos de balsa de un año y medio en promedio, está ubicado al noreste de la parroquia rural de Los Vergeles entre los recintos la Magdalena, Gualipe, y las Chávicas.



**Figura. 12** Ubicación geográfica del área 2 de estudio

Elaborado por: Quintana J, Tituaña K, (2019)

El clima existente en la zona según la clasificación climática de Thornthwaite es tropical mega térmico húmedo la cual presenta dos estaciones bien marcadas, una seca que comprende los meses de mayo a diciembre y una lluviosa que abarca los meses restantes (INAMHI, 2017), la temperatura promedio oscila entre los 24 a 25 °C con una precipitación media anual entre los 3000- 31000 mm, con respecto a la humedad relativa dependiendo de la época varía entre 70 a 90 % (IEE, 2013).

Esta zona se encuentra a un rango altitudinal de 252- 272 m.s.n.m., presenta un suelo no salino, poco profundo con buen drenaje; posee una textura franca en la superficie (0 a 20 cm) y franca arenosa a profundidad (21 a 50 cm), tiene un pH ligeramente ácido y una fertilidad mediana (PLANTABAL S.A., 2015).


## 4.2. Fases de estudio

### 4.2.1. Fase de planificación


La fase de planificación está dada por el tiempo utilizado antes de acudir a campo, en la cual se realizó una recopilación de información bibliográfica, se planificaron los vuelos, se identificó el tipo muestreo a aplicarse, además del empleo de softwares para el uso del vehículo aéreo no tripulado.

#### 4.2.1.1. Planificación de los vuelos

Por medio del software eMotion se realizaron dos planes de vuelo mensuales durante tres meses para cada área de estudio el primero para utilizarse con la cámara thermoMAP y el segundo con la cámara Parrot sequoia; con la finalidad de poder determinar la trayectoria de vuelo; el solape, traslape y número de imágenes a captarse por el dron, además de poder estimar el área, la distancia, la altura y el tiempo de vuelo recorrido para el mismo, como se puede observar en la imagen a continuación.







**Figura. 13** De arriba hacia abajo planificación de vuelo para el área 1 y 2 con la cámara Parrot sequoia


Elaborado por: Quintana J, Tituaña K, (2019)

Es necesario recalcar que la planificación de vuelo se lo realiza con la finalidad de ahorra tiempo y recursos en campo.

#### 4.2.1.2. Muestreo de suelo


El muestreo seleccionado para las áreas se estudió es aleatorio compuesto con un patrón o recorrido en forma de X el cual se basa en tomar como puntos de muestreo cada esquina y el centro del lote, cabe señalar que se toma como sub muestras el largo de la X para poder mezclarlas posteriormente y formar una muestra compuesta. Este tipo de muestreo se seleccionó con la finalidad de economizar recursos en la investigación (Mendoza & Espinoza, 2017).

La planificación se la realizo con la ayuda del software ArcGIS donde se diseñó la ruta y puntos de muestreo, de los cuales se generaron sus respectivas coordenadas para poder tener una guía de ubicación en campo y facilitar la toma de muestras como se presentan en las siguientes imágenes del área 1 y área 2 de estudio.



**Figura. 1** Diseño de ruta y puntos de muestreo del área 1 de estudio

Elaborado por: Quintana J, Tituaña K, (2019)



**Figura. 2** Diseño de ruta y puntos de muestreo para el área 2

Elaborado por: Quintana J, Tituaña K, (2019)

#### **4.2.2. Fase de campo**

Esta etapa se dedicó a la recolección de información primaria para posteriormente ser procesada o destinada a los diferentes análisis de laboratorio; esta fase se divide en toma de muestras de suelo y recolección de imágenes aéreas.

##### **4.2.2.1. Toma de muestras**

Con respecto a las herramientas empleadas para este muestreo fueron un azadón, pala, espátula, balde, guantes, fundas ziploc, etiquetas, rotulador, GPS de precisión, cooler y hielo, las mismas que se encontraron completamente limpias o desinfectadas antes de cada toma de muestra o sub muestra.

En cuanto a la toma de muestras se procedió a realizar un muestreo superficial de acuerdo a lo que dicta la normativa (ISO 18400, 2018) para calidad del suelo y muestreo, en la que se estipula que dependiendo del tipo de investigación y parámetros a analizarse deben tomarse las muestras; además hay que tomar en cuenta parámetros generales como la profundidad, uso del suelo, tipo de cultivo, textura y si existe o no la presencia de algún contaminante.

Para la obtención de las muestras en primer lugar se limpió la superficie del suelo a muestrear, seguido se realizó una excavación en forma de V de 25 a 30 cm de profundidad (AGROCALIDAD, 2015) desde la hojarasca de suelo hasta el cambio de color con una pala posterior a esto se extrajo 5 cm de grosor de suelo de una de las paredes (ISO 18400, 2018); con una espátula se eliminó los extremos laterales y se extrajo 5 cm de ancho, a continuación se depositó la submuestra en el balde y se homogenizó (AGROCALIDAD, 2015); se siguió el mismo procedimiento para las submuestras planificadas por cada punto de muestreo. Una vez obtenida la muestra se colocó en una funda ziploc eliminando en lo más posible el exceso de aire y se



procedió a etiquetar para finalmente guardarlos en un contenedor con hielo a 4 °C para su preservación.

#### **4.2.2.2. Recolección de imágenes aéreas**

Para la toma de imágenes aéreas se empleó el dron Ebee el mismo que realizó dos vuelos en cada área de estudio con las cámaras thermoMAP y Parrot sequoia, por consecuente para cada uno de estos se tuvo que considerar diversos factores como son la velocidad de viento, tiempo climático, cobertura vegetal, hora y lugar de lanzamiento; también cabe mencionar que la recolección de imágenes comienza con el lanzamiento del dron el cual fue monitoreado con el programa eMotion durante todo su vuelo y aterrizaje; para ello hay diseñar bien en el plan de vuelo, el cono de salida y aterrizaje además de buscar una zona despejada y con un buen amortiguamiento en el suelo, con la finalidad de evitar accidentes, pérdidas o daños al equipo.



**Figura. 14** De izquierda a derecha toma de muestra de suelo y lanzamiento del dron eBee- área 2

Elaborado por: Quintana J, Tituaña K, (2019)

#### **4.2.3. Fase de análisis - parámetros del suelo**

Para la obtención de nitrógeno total y materia orgánica se lo realizó a través de dos entidades acreditadas por el SAE, mientras que para los parámetros restantes se utilizaron las instalaciones de la Universidad Politécnica Salesiana- Quito campus sur, en los laboratorios de química e instrumental.

##### **4.2.3.1. Determinación de nitrógeno total**

Este parámetro fue realizado en los laboratorios de la Oferta de servicios y productos (OSP) perteneciente a la facultad de ciencias químicas de la Universidad central del Ecuador. El método de análisis empleado fue por Kjeldahl reconocido como metodología oficial dentro de la norma ISO 11261, el cual emplea una digestión del suelo seguido de una destilación del mismo para finalmente realizarse una valoración de los resultados (Panreac, 2015).

La cadena de custodia seguida se llevó acorde a los parámetros establecidos por la entidad competente, los cuales fueron: realizar un etiquetado donde conste, nombre del responsable del muestreo, identificación del sitio, coordenadas en X, Y, Z, código de identificación de muestra y ser transportadas a 4 °C, sin variación de temperatura y evitando el contacto con sustancias que puedan alterar su composición. Por último, informar del número de muestras y el parámetro a analizar en el momento de la entrega.

##### **4.2.3.2. Determinación de materia orgánica**

La determinación de este parámetro se lo realizó en los laboratorios de Agrocalidad, el mismo que se encuentra aprobado por el servicio de Acreditación Ecuatoriana y El Ministerio del Medio Ambiente. El método analítico empleado fue

el de Walkley y Black, la cadena de custodia establecida por la entidad competente fue seguida de la misma forma que el anterior apartado.

#### **4.2.3.3. Análisis en laboratorio**

##### **4.2.3.3.1. Preparación de la muestra**

Las muestras obtenidas en campo dependiendo del análisis a realizarse fueron sometidas a un secado al ambiente o térmico.

- **Secado al ambiente.**

Se tomó 250 gramos de cada una de las muestras y se esparcieron individualmente en un sitio plano evitando el contacto directo con el suelo para impedir todo tipo de contaminación, se dejó reposar por 24 horas. Durante este proceso se retiró cualquier fragmento distinto al suelo como, materia orgánica, rocas, o vidrios y con un rodillo de madera se apisonó los agregados mayores a 15 mm una vez seco el suelo se pasó por un tamiz de 2 mm, se mezcló homogéneamente cada una de las muestras y se almacenaron en funda plásticas sin aire para su posterior uso (ISO 11464, 2006)

##### **4.2.3.3.2. Determinación de pH**

*Materiales y equipos:*

- pH metro.
- Balanza analítica
- Espátula
- Vasos de precipitación de 300 ml
- Agitadores magnéticos
- Agitador
- Agua purificada

**Determinación de pH:** Se tomó 10 g de suelo en 25 ml de agua purificada y se colocó en una plancha de agitación por 5 minutos a 5 rpm. Una vez transcurrido

este tiempo se dejó en reposo por 30 min para que se sedimenten las muestras, posterior a esto se realiza las lecturas con el pH metro. Para la lectura del pH se tomaron en cuenta los siguientes criterios:

**Tabla 2** Tipo de suelo de acuerdo a sus rangos de pH.

Rango – Ph	Tipo de suelo
< 3.5	Ultra ácido
3.5 – 4.4	Extremadamente ácido
4.5 - 5.0	Fuertemente muy ácido
5.1 - 5.5	Fuertemente ácido
5.6 - 6.0	Moderadamente ácido
6.1 - 6.5	Levemente ácido
6.6 – 7.3	Neutro
7.4 - 7.8	Levemente alcalino
7.9 - 8.4	Moderadamente alcalino
8.5- 9.0	Muy alcalino
> 9.0	Extremadamente alcalino

Elaborado por: Quintana J, Tituaña K, (2019)  
Fuente: (USDA, 2017)



**Figura. 15** Determinación de pH  
Elaborado por: Quintana J, Tituaña K, (2019)

#### 4.2.3.3.3. Determinación de humedad.

*Materiales y equipos:*

- Crisoles
- estufa
- balanza analítica

**Procedimiento:** se pesaron 20 gramos de suelo húmedo en una balanza analítica, se colocaron las muestras en crisoles de 100 gramos, seguido a esto se introdujeron en una estufa a 105 °C por 24 horas, pasado este tiempo se volvió a pesar (Radojevic & Bashkin, 2006).

Para la estimación de la Humedad se empleó el siguiente calculo:

$$\%Humedad = \frac{Peso\ inicial\ (g) - peso\ final\ (g)}{peso\ inicial\ (g)} * 100$$

#### 4.2.3.3.4. Determinación de Textura

El método aplicado para el análisis fue el de Bouyoucuos, el cual permite la determinación del tamaño de partículas por su densidad. Este análisis se realizó con la finalidad de obtener información de apoyo de las áreas del estudio.

#### 4.2.3.3.5. Determinación de Fósforo

Se empleó el método de espectrofotometría denominado Bray II, esta técnica nos permite la medición de la energía que absorben las moléculas en un analito según la longitud de onda que logra pasar atreves de un prisma (MCkean, 1993).



Es importante mencionar que el siguiente procedimiento no es viable en suelos con  $\text{pH} > 6.8$ , o que hayan sido sometidos a fertilización, o algún tratamiento químico que pueda alterar el parámetro.

### *Materiales y equipos*

Los materiales, equipos y sustancias empleadas se detallan a continuación:

#### *Sustancias*

- Fluoruro de sodio
- Ácido sulfúrico
- Molibdato de amonio
- Ácido clorhídrico
- Tartrato de amonio y potasio
- Fosfato de sodio
- Ácido ascórbico
- Agua destilada o purificada

#### *Materiales y equipos*

- Matraz Erlenmeyer
- Vasos de precipitación
- Micropipeta
- Embudo
- Tubo falcón
- Mufla
- Embudo
- Kitasato
- Ultrasonido
- Bomba al vacío
- Centrifuga

### **Procedimiento:**

Para la obtención de fósforo en una muestra de suelo se debe realizar los siguientes subprocesos:

#### *A. Preparación de solución extractora*

Pesar 0.275 g de NaF y colocar en un matraz de 250 ml agregar agua destilada hasta  $\frac{1}{4}$  y disolver en un ultrasonido, a continuación, aforar el mismo y agregar 6.25 ml de ácido clorhídrico aforar con agua destilada limpiando todos los residuos, agitar ligeramente 3 veces y etiquetar.

### ***B. Preparación de reactivo mixto***

Disolver 0.36 g de molibdato de amonio en 11.9 ml de agua destilada, 3.33 de ácido sulfúrico en 21.45 ml de agua purificada, 0.26 g de ácido ascórbico en 4.75 ml de agua purificada a y 0.016 g de tartrato de amonio y potasio en 11.9 ml de agua purificada, finalmente mezclar en el mismo orden.

### ***C. Obtención de curva de calibración***

Primeramente, realizar una solución patrón de 50 ppm (pesando 0.5010 g de fosfato de sodio en un matraz de 250 ml), diluir la solución y aforar. seguido de ello agitar y etiquetar. En un balón de 100 ml añadir 20 ml de solución patrón, añadir 20 ml de solución extractora y 5 de reactivo mixto y aforar. En 5 balones de 25 ml colocar soluciones de 25 ml, 20 ml 15 ml, 10 ml y 5 ml respectivamente para obtener concentraciones de 10, 8, 6, 4, 2 ppm. Encender el espectrofotómetro de 885 nm y realizar la lectura de calibración.



**Figura. 16** Análisis de fósforo en laboratorio

Elaborado por: Quintana J, Tituaña K, (2019)

### ***D. Lectura de resultados***

Pesar 50 g de suelo previamente tamizada, colocar en una mufla a 900 ° C durante 15 minutos. moler y pesar 0.625 g, colocar en un tubo falcón y agregar 6.25 ml de


solución extractora, llevar a agitación durante 15 min.; seguido de ello colocar durante 10 min. en una centrifuga a 2000 rpm, recoger sobrenadante y filtrar. Para la lectura agregar 0.5 ml de sobrenadante, en 2 ml de agua purificada y 0.5 ml de reactivo mixto dejar reposar 30 minutos exactos y realizar la lectura.

#### 4.2.4. Procesamiento de la información

En esta etapa se realizó el procesamiento de las imágenes captadas por el dron y el cálculo de los índices ambientales: NDVI, GNDVI, NDRE, SMI y NDWI, empleados en la investigación.

##### 4.2.4.1. Generación de raster térmicos


Este proceso se lo realizo por medio de las imágenes térmicas obtenidas por la cámara thermoMAP, a través del programa Pix4D donde se generaron los raster térmicos de la temperatura superficial del terreno, los mismos que serán empleados para calcular el índice de humedad del suelo o SMI de las áreas de estudio.



**Figura. 17** Raster de temperatura para el área 1 de estudio.  
Elaborado por: Quintana J, Tituana K, (2019)

#### 4.2.4.2. Obtención de orto fotos


De igual manera este parte se lo realizo con el software anteriormente mencionado; con la finalidad de poder emplear las ortofotos generadas por el programa para la identificación de la zona y puntos de muestreo durante las salidas al campo.



**Figura. 18** Generación de un orto mosaico para el área 1 de estudio  
Elaborado por: Quintana J, Tituaña K, (2019)

#### 4.2.4.3. Calculo de NDVI

El software Pix4D cuenta con una calculadora de índices incorporada la cual permite estimar el NDVI a través de las imágenes obtenidas por la cámara Parrot sequoia en campo, este proceso se lo realiza de forma automática una vez haya sido seleccionada en las opciones de procesamiento o en la calculadora de índices.




**Figura. 19** Obtención del índice de NDVI para el área 2 de estudio  
Elaborado por: Quintana J, Tituaña K, (2019)

#### 4.2.4.4. Calculo de SMI (Soil moisture index)


Este índice permite evaluar el contenido de humedad del suelo, permitiendo identificar los lugares húmedos y con sequía a través de un rango que va de cero a uno; donde el cero indica los lugares con alta vegetación y temperatura superficial que poseen poca humedad del suelo y uno los lugares con poca vegetación y temperatura superficial con alto contenido de humedad (Saha et al., 2018).

$$SMI = \frac{LST_{max} - LST}{LST_{max} - LST_{min}}$$

El cálculo de este índice se lo realizo por medio del software ArcGIS empleando la herramienta raster calculador del ArcToolbox como se muestra a continuación.



**Figura. 20** Cálculo del índice de humedad SMI para el área 1  
Elaborado por: Quintana J, Tituaña K, (2019)




**Figura. 21** Raster del índice de humedad SMI para el área 1  
Elaborado por: Quintana J, Tituaña K, (2019)

#### 4.2.4.5. Cálculo de NDRE


Este índice normalizado de borde rojo permite generar una imagen que puede estimar el contenido de clorofila y estado del nitrógeno, posee valores parecidos al NDVI que van de -1 a 1 (Rodríguez et al., 2006).



$$NDRE = \frac{NIR - Red\_edge}{NIR + Red\_edge}$$



**Figura. 22** Cálculo del índice de NDRE para el área 1  
Elaborado por: Quintana J, Tituaña K, (2019)




**Figura. 23** Raster del índice de NDRE para el área 1  
Elaborado por: Quintana J, Tituaña K, (2019)


#### 4.2.4.6. Cálculo de GNDVI

El índice de verdor GNDVI genera información acerca del estado de la vegetación de acuerdo a la actividad fotosintética, la cantidad de nitrógeno y el contenido de agua en la vegetación, es un índice que se puede emplear en ciertas etapas del cultivo principalmente en intermedia y final (Kharuf et al., 2018) .

$$GNDVI = \frac{NIR - B_{Green}}{NIR + B_{Green}}$$



**Figura. 24** Cálculo del índice GNDVI para el área 2  
Elaborado por: Quintana J, Tituaña K, (2019)




**Figura. 25** Raster del índice de GNDVI para el área 2  
Elaborado por: Quintana J, Tituaña K, (2019)

#### 4.2.4.7. Cálculo de NDWI


El índice de NDWI nos permite generar imágenes donde se observe el cambio del contenido de H<sub>2</sub>O en el suelo, pudiendo así determinar el estrés hídrico del mismo, los rangos van de -1 a 1 (Xu, 2006).

$$NDWI = \frac{B_{Green} - NIR}{B_{Green} + NIR}$$





**Figura. 26** Cálculo del índice de agua NDWI para el área 1  
Elaborado por: Quintana J, Tituaña K, (2019)



**Figura. 27** Raster del índice de agua NDWI para el área  
Elaborado por: Quintana J, Tituaña K, (2019)

### 4.3. Diseño del modelo

Para el diseño del modelo se tomaron como datos los parámetros de nitrógeno total (NT), materia orgánica (MO), humedad (H) y fósforo (P), que fueron obtenidas por medio del análisis ejecutado para cada una de las mismas después de cada salida realizada a las áreas de estudio, ubicadas cerca del recinto “El Vergel”, provincia de Los Ríos, realizado en los meses de marzo, abril y mayo de 2019.

También se empleó como información los índices obtenidos del cálculo de las imágenes conseguidas en el programa ArcGIS, que fueron proporcionadas por el drone.

#### **4.3.1. Planteamiento de la hipótesis**

Se determinaron dos hipótesis (nula y alternativa) de manera generalizadas para cada uno de los modelos aplicados en esta investigación, los cuales nos permitirán determinar la validez de los mismos.

**Hipótesis nula ( $H_0$ ):** La probabilidad de presencia de anormalidades y alteraciones del suelo no se puede estimar mediante el cálculo de índices de reflectancia espectral.

**Hipótesis alternativa ( $H_i$ ):** La probabilidad de presencia de anormalidades y alteraciones del suelo si se puede estimar mediante el cálculo de índices de reflectancia espectral.

#### **4.3.2. Modelo de regresión lineal**

Considerando la verisimilitud de los datos, la distribución de los mismo alrededor de una recta y la aplicación de una sola variable regresiva o independiente, que para este estudio son los índices de reflectancia espectral mencionados en la *sección 3.4*, se optó por la aplicación de un modelo de regresión lineal simple (MRLS), este tipo de modelos se emplea para varios propósitos como son la estimación y predicción de parámetros (Montgomery et al., 2012).

Al mismo tiempo se consideró como variable respuesta o dependiente, los parámetros de estudio de calidad del suelo que son: “NT”, “MO”, “P” y “humedad”.

#### 4.3.2.1. Aplicación de la correlación de datos

Para verificar la correlación lineal entre la variable predictiva y regresiva se realizó un análisis de correlación de las mismas empleando el programa de RStudio y los paquetes “corroplot” y “GGally”, los mismos que permitieron obtener gráficos de correlación para cada una de las variables estudiadas.

#### 4.3.2.2. Ejecución del MRLS

Con la ayuda del programa RStudio se realizó el modelo de regresión lineal, así como todas las pruebas de diagnóstico, selección y validación del mismo.

Los paquetes que se emplearon para este análisis fueron “lmtest”, “car” y “caret” el primero permitió realización de las pruebas para validar los supuestos del modelo de regresión (*ver sección 3.10.3*), para identificar los residuos asilados del modelo se empleó el segundo paquete, mencionado, y para realizar la validación del modelo se empleó el tercero, para validar los supuestos de la regresión también se emplearon gráficos de diagnóstico.

```
#generación del modelo con respecto a NI
library(car)
library(caret)
MLM1<- lm(N_Total~NDVI, data=CNT)
summary(MLM1)
MLM2<- lm(N_Total~GNDVI, data=CNT)
summary(MLM2)
MLM3<-lm(N_Total~NDRE, data=CNT)
summary(MLM3)
MLM4<-lm(N_Total~NDWI, data=CNT)
summary(MLM4)
MLM5<-lm(N_Total~SMI, data=CNT)
summary(MLM5)

library(lmtest)
#Evaluación de los supuestos del modelo#
#Independencia----- Durbin-Watson
dwtest(REG1)
dwtest(REG2)
dwtest(REG3)
dwtest(MLM4)
dwtest(MLM5)

#Test de hipótesis para el análisis de normalidad de los residuos
shapiro.test(REG1$residuals)
shapiro.test(REG2$residuals)
shapiro.test(REG3$residuals)
shapiro.test(MLM4$residuals)
shapiro.test(MLM5$residuals)

#Test de contraste de homocedasticidad Breusch-Pagan
bptest(REG1)
bptest(REG2)
bptest(REG3)
bptest(MLM4)
bptest(MLM5)

# valores aislados del modelo
outlierTest(MLM1)
outlierTest(MLM2)
outlierTest(MLM3)
outlierTest(MLM4)
outlierTest(MLM5)
```

**Figura. 28** Porción de código para la obtención de la regresión y pruebas.

Elaborado por: Quintana J, Tituaña K, (2019)

#### **4.3.2.3. Prueba de Durbin Watson**

Esta prueba se empleó para determinar la independencia de los residuos y cumplir uno de los supuestos de una regresión lineal.

#### **4.3.2.4. Prueba Shapiro Wilk**

Este tipo de diagnóstico se empleó para verificar que los errores residuales están normalmente distribuidos.

#### **4.3.2.5. Prueba de contraste Breusch-Pagan**

Esta prueba de diagnóstico se utilizó para comprobar que los residuos poseen una igual varianza también conocido como homoscedasticidad.

#### **4.3.2.6. Predicción del modelo**

La predicción del modelo se lo realizó para las cinco variables empleadas para predecir el parámetro de estudio, una vez realizado este proceso se empleó el comando “ggplot” que realiza un gráfico de dispersión indicando la banda de confianza y predicción para cada uno de los cinco modelos por parámetro de estudio.


#### **4.3.2.7. Criterio de información Akaike**

Este criterio permitió la elección del mejor modelo para cada uno de los parámetros evaluados en base a la predicción del mismo, su número de parámetros y su verosimilitud (Kassambara, 2018c) .

#### **4.3.2.8. Validación cruzada K-Fold**

Con la finalidad evaluar el rendimiento los modelos y saber cómo se generalizan a un conjunto de datos independientes se realizó una validación cruzada K-Flod, esto ayudara a saber cómo funcionará el mismo con un conjunto de datos independientes,

a través de la subdivisión de la información conocido como datos de entrenamiento y por medio del cálculo del error de predicción (Kassambara, 2018a).



**Figura. 29** Diagrama de proceso de la investigación  
Elaborado por: Quintana J, Tituaña K, (2019)

## 5. RESULTADOS Y DISCUSIÓN

Se recolectaron datos en campo durante los días iniciales del mes de marzo, abril y mayo del año 2019, para cada uno de los parámetros estudiados como son N, P, MO, humedad y los índices obtenidos a través del cálculo de las bandas de las imágenes conseguidas por el dron.

### 5.1. Resultados de los parámetros de calidad del suelo

Una vez realizado los análisis de laboratorio se presentan los resultados de cada uno de las variables estudiadas que se emplearon como parámetros dependientes en la realización del modelo.

**Tabla 3** Parámetros de calidad del suelo para el área 1.

<b>Área 1 (Plantación PR02)</b>						
<i>Salida</i>	<i>Fecha</i>	<i>Muestra</i>	<i>N_Total</i> %	<i>MO</i> %	<i>Fósforo</i> ppm	<i>Humedad</i> %
Primera salida	04/03/2019	1p1a1	0,4389	4,58	25,6951	33,1
		1p2a1	0,3479	3,5	24,8251	33,9
		1p3a1	0,3663	4,38	25,4263	29,6
		1p4a1	0,2743	2,76	22,3352	24,2
		1p5a1	0,2723	2,76	22,6594	24,7
Segunda salida	05/04/2019	2p1a1	0,3082	3,35	23,9813	31,6
		2p2a1	0,2566	3,25	21,9043	29,5
		2p3a1	0,2463	2,91	23,4643	30,4
		2p4a1	0,3041	2,52	24,8862	32
		2p5a1	0,2389	2,12	20,9663	27,9
Tercera salida	03/05/2019	3p1a1	0,2303	3,12	23,3512	30,7
		3p2a1	0,2829	2,81	22,4139	25,4
		3p3a1	0,254	3,29	22,1721	30,2
		3p4a1	0,2443	2,65	22,4124	28,8
		3p5a1	0,2563	3,3	24,1697	31,5

Elaborado por: Quintana J, Tituaña K, (2019)

Es importante tomar en cuenta que el código empleado en la columna “**muestra**” de las *tablas 3 y 4*, representan de izquierda a derecha el número de salida, el punto tomado y el área de trabajo.

**Tabla 4** Parámetros de calidad del suelo para el área 2.

<b>Área 2 (Plantación FuturaCorp 06 )</b>						
<i>Salida</i>	<i>Fecha</i>	<i>Muestra</i>	<i>N_Total</i> %	<i>MO</i> %	<i>Fósforo</i> ppm	<i>Humedad</i> %
Primera salida	05/03/2019	1p1a2	0,3707	4,29	25,0783	33,6
		1p2a2	0,4759	4,44	28,2326	41,1
		1p3a2	0,4828	4,9	27,092	43,5
		1p4a2	0,4381	4,82	26,6801	36,3
		1p5a2	0,3896	4,23	24,1201	38,7
Segunda salida	06/04/2019	2p1a2	0,3991	4,16	25,8204	38,1
		2p2a2	0,4496	4,32	25,5387	30,4
		2p3a2	0,3093	3,43	27,1127	34,7
		2p4a2	0,3333	4,54	24,7446	36,3
		2p5a2	0,2742	3,15	22,6474	27,6
Tercera salida	04/05/2019	3p1a2	0,2904	3,54	25,0829	29
		3p2a2	0,2003	2,35	22,6236	24,2
		3p3a2	0,2387	3,05	23,4427	34,9
		3p4a2	0,3175	4,85	23,6626	37,2
		3p5a2	0,2192	3,83	23,4649	31

Elaborado por: Quintana J, Tituaña K, (2019)

Cabe mencionar que no se incluyeron como datos de análisis dentro del modelo a la textura y el pH ya que se emplean como datos de apoyo o como información extra del suelo en el que se está realizando la investigación.

Por otra parte, tanto el área 1 como el área 2 *poseen una textura franco arenosa un pH ligeramente ácido a neutro con un promedio para la primera área de 6.79 y en la segunda de 6.72.*

## 5.2. Resultados de los índices de reflectancia espectral

Se emplearon cinco índices que abarcan vegetación, agua, y borde rojo, calculados mensualmente por tres meses para cada una de las salidas, estos fueron empleados como variables independientes dentro de los modelos de regresión generados.



**Tabla 5** Índices de reflectancia espectral para el área 1.

<b>Área 1 (Plantación de PR02)</b>							
<i>Salida</i>	<i>fecha</i>	<i>Muestra</i>	<i>NDVI</i>	<i>NDRE</i>	<i>GNDVI</i>	<i>NDWI</i>	<i>SMI</i>
Primera salida	04/03/2019	1p1a1	0,3574	0,2874	0,3342	0,2914	0,8449
		1p2a1	0,1843	0,1834	0,2837	0,1599	0,8835
		1p3a1	0,3088	0,249	0,2646	0,1691	0,8256
		1p4a1	0,124	0,0689	0,2314	0,1571	0,7789
		1p5a1	0,1553	0,1116	0,1288	0,0932	0,786
Segunda salida	05/04/2019	2p1a1	0,3461	0,1088	0,2801	0,2274	0,8556
		2p2a1	0,0747	0,0628	0,1597	0,1441	0,8565
		2p3a1	0,0522	0,0917	0,1829	0,2096	0,844
		2p4a1	0,2705	0,1081	0,2118	0,2007	0,8153
		2p5a1	0,0435	0,1009	0,1401	0,1533	0,7827
Tercera salida	03/05/2019	3p1a1	0,1079	0,0535	0,1478	0,129	0,8562
		3p2a1	0,1476	0,1334	0,1778	0,0943	0,8431
		3p3a1	0,1857	0,1525	0,1297	0,1594	0,8078
		3p4a1	0,1755	0,1161	0,2291	0,1055	0,7967
		3p5a1	0,2042	0,1342	0,1122	0,1115	0,8434

Elaborado por: Quintana J, Tituaña K, (2019)

**Tabla 6** Índices de reflectancia espectral para el área 2.

<b>Área 2 (Plantación FuturaCorp 06 (FC06) )</b>							
<i>Salida</i>	<i>Fecha</i>	<i>Muestra</i>	<i>NDVI</i>	<i>NDRE</i>	<i>GNDVI</i>	<i>NDWI</i>	<i>SMI</i>
Primera salida	05/03/2019	1p1a2	0,2315	0,1235	0,215	0,2642	0,8942
		1p2a2	0,3574	0,2906	0,3563	0,3456	0,9167
		1p3a2	0,3823	0,2035	0,3826	0,3754	0,9073
		1p4a2	0,3743	0,2549	0,3247	0,2557	0,8852
		1p5a2	0,254	0,2138	0,3517	0,3314	0,893
Segunda salida	06/04/2019	2p1a2	0,3214	0,1908	0,2722	0,1982	0,9046
		2p2a2	0,3697	0,2434	0,3812	0,2901	0,869
		2p3a2	0,2527	0,127	0,2161	0,2759	0,8604
		2p4a2	0,2106	0,1534	0,2365	0,2686	0,8922
		2p5a2	0,1083	0,097	0,1978	0,1035	0,8085
Tercera salida	04/05/2019	3p1a2	0,2158	0,1073	0,1657	0,2657	0,7987
		3p2a2	0,0891	0,0903	0,1247	0,1761	0,7524
		3p3a2	0,1587	0,0777	0,204	0,2259	0,8827
		3p4a2	0,1996	0,164	0,2887	0,3195	0,8955
		3p5a2	0,1504	0,0983	0,1478	0,2847	0,8058

Elaborado por: Quintana J, Tituaña K, (2019)

### 5.3. Análisis de correlación

Se emplearon cuatro parámetros de calidad del suelo para analizar la correlación que poseen estos con los índices de reflectancia estudiados.




Figura. 30 Correlación existente entre las variables respecto al NT.  
Elaborado por: Quintana J, Tituaña K, (2019)






Figura. 31 Correlación existente entre las variables respecto a la MO  
Elaborado por: Quintana J, Tituaña K, (2019)



**Figura. 32** Correlación existente entre las variables respecto al P.  
Elaborado por: Quintana J, Tituaña K, (2019)



**Figura. 33** Correlación existente entre las variables respecto a la humedad  
Elaborado por: Quintana J, Tituaña K, (2019)

#### 5.4. Variables empleadas para los modelos

**Tabla 7** Variables dependientes e independiente empleadas en los modelos..

Modelos simulados	Variable dependiente	Variable independiente
Calidad del suelo: Contenido de N, P y MO	Nitrógeno total %	NDVI ( <i>Índice de vegetación</i> )
	Materia Orgánica %	GNDVI ( <i>Índice de vegetación</i> )
	Fósforo ppm	NDRE ( <i>Índice de borde rojo</i> )
Estrés hídrico	Humedad %	NDWI ( <i>Índice de agua</i> )
		SMI ( <i>Índice de estrés hídrico</i> )

Elaborado por: Quintana J, Tituaña K, (2019)

#### 5.5. MRL para la estimación de contenido de nitrógeno

Se realizó un total de cinco modelos de regresión lineal con cada uno de las variables independientes descritas en la *tabla 7*, para ello se empleó la función “lm” que permite ajustar modelos lineales y la función summary para obtener los estadísticos básicos del modelo. Donde  $\beta_0$  y  $\beta_1$  es la intercepción y el coeficiente de la variable,  $Pr(>|t|)$  indica el nivel de significancia para cada uno de los beta.

**Tabla 8** Resumen estadístico de los coeficientes del MRL de N

Variable independiente del MRL	Coeficientes de importancia			
	$\beta_0$	$\beta_1$	$Pr(> t )$	$Pr(> t )$
			$\beta_0$	$\beta_1$
NDVI	0.17015	0.68695	2.29e-10	6.32e-10
GNDVI	0.11219	0.89325	6.65e-06	2.21e-10
NDRE	0.16217	1.05624	6.65e-10	2.47e-10
NDWI	0.17813	0.65245	7.37e-06	9.02e-05
SMI	-0.7213	1.2270	0.00218	4.01e-05

Elaborado por: Quintana J, Tituaña K, (2019)

**Tabla 9** Resumen estadístico de la bondad de ajuste del MRL

Variable independiente del MRL	Bondad de ajuste del MRL			
	<i>RSE</i>	<i>R<sup>2</sup></i>	<i>R<sup>2</sup> ajustado</i>	<i>p-value</i>
NDVI	0.04126	0.7501	0.7412	6.319e-10
GNDVI	0.03664	0.8029	0.7958	2.212e-11
NDRE	0.03991	0.7662	0.7578	2.47e-10
NDWI	0.06247	0.427	0.4066	9.022e-05
SMI	0.06076	0.4581	0.4387	4.012e-05

Elaborado por: Quintana J, Tituaña K, (2019)

Como se puede apreciar en la *tabla 9* la regresión con la variable independiente que más se ajusta al modelo es el GNDVI con un *R<sup>2</sup> ajustado* de 0.7958 y un *RSE* de 0.03664; de igual forma el índice NDRE presenta también un buen *R<sup>2</sup> ajustado* de 0.7578, el cual se respalda con un *RSE* de 0.03991, el índice que menor se ajusta al modelo es el NDWI ya que presenta un *R<sup>2</sup> ajustado* 0.4066 y un *RSE* de 0.06247. Hay que mencionar también que al poseer un p-value inferior a 0.05 se valida la hipótesis alternativa plantada en la *sección 4.3.1* y se rechaza la nula.


#### 5.5.1. Evaluación de los supuestos de regresión lineal

Para la evaluación de los supuestos de regresión lineal se emplearon parcelas diagnóstico y pruebas para validar los mismos.

##### 5.4.1.1. Parcelas de diagnóstico

A continuación, se detalla completamente los supuestos de regresión para el índice de NDVI, por medio de gráficos de diagnóstico, para los demás índices solo se presentará las parcelas de linealidad y valores influyentes.


### 5.5.1.1.1. Gráficos de diagnóstico para la validación los supuestos de regresión lineal con respecto al NDVI



**Figura. 34** Parcelas de diagnóstico aplicadas a la regresión de N con respecto a NDVI  
Elaborado por: Quintana J, Tituaña K, (2019)

Como se puede apreciar en la primera grafica de la figura anterior la nube de puntos de los residuos siguen una linealidad, de igual forma en el gráfico de distribución normal se aprecia que alguno de los residuos no siguen la línea recta de tal manera que la normalidad se comprobara con la ejecución de la prueba de Shapiro-Wilk, el tercer grafico se puede observar que los residuos se reparten homogéneamente lo que aprueba la homocedasticidad, finalmente el grafico de curva Cook no señala ningún punto influente que sobrepase la distancia de aplacamiento.


### 5.5.1.1.2. Gráficos de diagnóstico de linealidad de los MLR



**Figura. 35** Parcelas de diagnóstico para linealidad para N.  
Elaborado por: Quintana J, Tituaña K, (2019)

En la figura anterior se puede apreciar que se cumplen los supuestos de linealidad para cada uno de los índices empleados dentro de los MRL, considerando el parámetro nitrógeno, en los cuales se puede observar una adecuada distribución de la nube de puntos de los residuos de forma horizontal, cabe mencionar que la línea roja debe acercarse inicialmente a cero un punto importante es que la presencia de patrones dentro de la nube de puntos puede indicar algún problema de linealidad en el modelo.

### 5.5.1.1.3. Gráficos de diagnóstico para la estimación de valores influyentes.



**Figura. 36** Gráficas Cook aplicadas a la regresión de N.  
Elaborado por: Quintana J, Tituaña K, (2019)

Los gráficos anteriores nos facilitan la identificación de datos altamente influyentes de los modelos de regresión lineal, lo cual se puede observar que no existen valores atípicos en ningún MRL plantado para el caso del nitrógeno.

### 5.5.1.2. Pruebas de diagnostico

Para el análisis de los supuestos de regresión lineal y respaldar el diagnostico gráfico realizado anteriormente, se empleó tres tipos de pruebas, el primer test conocido como Durbin Watson, nos permite determinar la independendencia de los residuos, la segunda prueba es la de Shapiro Wilk, la cual nos facilita apreciar la normalidad de los errores, finalmente tenemos la prueba de contraste de Breusch-Pagan, la cual nos ayuda a analizar la homoscedasticidad de los datos.



Para mejor comprensión de estas pruebas con respecto a los MRL empleados se procedieron a agrupar en una tabla donde se evaluó cada uno de estos test con respecto al modelo regresión y su variable independiente, como se detalla a continuación.

**Tabla 10** Pruebas de diagnóstico aplicadas al MRL de N.

Variable independiente del MRL	Pruebas de diagnóstico de supuestos					
	Durbin Watson		Shapiro Wilk		Breusch-Pagan	
	DW	p-value	W	p-value	BP	p-value
NDVI	1.8508	0.3134	0.9442	0.1183	1.6499	0.1990
GNDVI	2.0539	0.5218	0.9722	0.6002	0.29162	0.5892
NDRE	1.7901	0.245	0.9654	0.423	0.2660	0.6060
NDWI	0.82081	9.607e-05	0.9662	0.441	3.3223	0.06825
SMI	1.1719	0.0065	0.9855	0.9459	3.0808	0.0792

Elaborado por: Quintana J, Tituaña K, (2019)

Continuando con nuestros análisis se puede apreciar que todos los residuos se distribuyen normalmente, ya que su p value es mayor a 0.05 para lo cual se rechaza la hipótesis alternativa de no normalidad, con respecto a la homoscedasticidad, donde solo tres índices cumplen la homogeneidad de varianza de los residuos ya que su p-value es mayor a 0.05, de misma manera ocurre con la prueba de independencia donde se repite el mismo caso, para el NDWI y SMI no cumplen con el supuesto de no auto correlación. Al no cumplir estos dos modelos con los supuestos de independencia y homoscedasticidad podrían ocasionar inferencias erróneas, ya que el método de mínimos cuadrados ya no es el más adecuado para predecir los estimadores de regresión (Uriel, 2013), *de tal manera estos dos índices no serán tomados en cuenta para estimar el contenido de nitrógeno.*

### 5.5.1.3. Selección y validación del mejor modelo

Para seleccionar el modelo que mejor ajusta con la variable predictor del mismo, se empleó el criterio de Akaike (AIC), posterior a esto se empleó una validación

cruzada K-Fold para evaluar el rendimiento y la estabilidad al ser empleado con un nuevo conjunto de datos de prueba.

**Tabla 11** Selección y validación del mejor modelo - N.


Variable independiente del MRL	Selección del mejor modelo <i>Criterio AIC</i>	Validación cruzada K-fold		
		<i>RSME</i>	<i>R<sup>2</sup></i>	<i>MAE</i>
NDVI	-102.2078	0.0393	0.7808	0.0360
GNDVI	-109.3248	0.0362	0.9240	0.0319
NDRE	-104.1998	0.0374	0.8109	0.0307
NDWI	-77.3135	0.0618	0.7758	0.0532
SMI	-78.9842	0.0549	0.75924	0.0485

Elaborado por: Quintana J, Tituaña K, (2019)

El modelo que mejor se ajusta para estimar el contenido de nitrógeno es el del GNDVI, ya que presente un AIC, error cuadrático medio y absoluto, más bajo en comparación a los demás índices además de contener un  $R^2$  de predicción de 0.9240, en segundo lugar, tenemos a NDRE con un  $R^2$  de 0.8109 seguido del NDVI que posee de igual forma un  $R^2$  de 0.7808.


#### 5.5.1.4. Intervalos de predicción y confianza de los modelos

A continuación, se presenta los intervalos de predicción y confianza por medio de gráficas para los mejores modelos diseñados para determinar el contenido de nitrógeno.




**Figura. 37** De izquierda a derecha: grafico de predicción de N con respecto al GNDVI y grafico de N conocido y simulado

Elaborado por: Quintana J, Tituaña K, (2019)



**Figura. 38** De izquierda a derecha: grafico de predicción de N con respecto a NDRE y grafico de N conocido y simulado  
Elaborado por: Quintana J, Tituaña K, (2019)



**Figura. 39** De izquierda a derecha: grafico de predicción de N con respecto al NDVI y grafico de N conocido y simulado  
Elaborado por: Quintana J, Tituaña K, (2019)

En las figuras anteriores del lado izquierdo se puede apreciar el intervalo de predicción de color rojo, así como de color gris la banda de confianza los cuales indican la distribución de los valores probables predichos alrededor de la recta regresión, tanto como respuesta individual y media. De la misma forma las figuras de la derecha indica la distribución en la recta de los valores observados sobre los predichos en los cuales se puede apreciar la linealidad de los mismos.

### 5.5.2. Ecuaciones de MRL para la obtención de Nitrógeno

En base a la formula general de regresión lineal simple se procede a plantear las ecuaciones correspondientes a cada uno de las variables regresivas

$$Y = \beta_0 + \beta_1 X$$

**Tabla 12** Ecuaciones planteadas para determinación de N.

Índice	Ecuación	$R^2$ ajustado	AIC
NDVI	$Y = 0.1702 + 0.6869530 \text{ NDVI}$	0.7412	-102.2078
GNDVI	$Y = 0.1122 + 0.8933 \text{ GNDVI}$	0.7958	-109.3248
NDRE	$Y = 0.1622 + 1.05624 \text{ NDRE}$	0.7578	-104.1998

Elaborado por: Quintana J, Tituaña K, (2019)

El mejor modelo para estimar nitrógeno es el GNDVI ya que presenta el menor valor de AIC y un  $R^2$  ajustado del 0.798

### 5.6. MRL para la estimación de contenido de MO

Se elaboraron cinco modelos lineales para las variables independientes descritas anterior mente. Por medio del comando “lm” se obtiene una regresión lineal y los datos estadísticos básicos se obtienen a partir del comando summary.

**Tabla 13** Resumen estadístico del modelo de regresión de MO

Variable independiente del MRL	Coeficientes de importancia			
	$\beta_0$	$\beta_1$	$Pr(> t )$ $\beta_0$	$Pr(> t )$ $\beta_1$
NDVI	2.3404	5.7671	2.33e-10	5.54e-06
GNDVI	1.903	7.286	1.48e-06	4.69e-06
NDRE	2.2506	9.0231	5.61e-10	2.13e-06
NDWI	2.0033	7.3756	1.64e-07	3.27e-06
SMI	-7.719	13.345	0.000523	69e-06

Elaborado por: Quintana J, Tituaña K, (2019)

**Tabla 14** Resumen de bondad y ajuste del MRL de MO.

Variable independiente del MRL	Bondad de ajuste del MRL			
	<i>RSE</i>	<i>R2</i>	<i>R2 ajustado</i>	<i>p-value</i>
NDVI	0.568	0.5274	0.5106	5.54e-06
GNDVI	0.5647	0.5329	0.5162	4.69e-06
NDRE	0.5495	0.5578	0.542	2.131e-06
NDWI	0.5577	0.5445	0.5282	3.27e-06
SMI	0.5601	0.5406	0.5242	3.691e-06

Elaborado por: Quintana J, Tituaña K, (2019)


Una vez analizados los resultados de los modelos de regresión podemos observar que el modelo con el  $R^2_{ajustado}$  más alto es el de NDRE con 0.542, mientras que el más pequeño es el de NDVI con 0.5106. Por otro lado, podemos analizar los valores de *RSE* de regresión donde el más pequeño es el del modelo NDRE con 0.5495 y los valores de *p-value* del mismo modelo siguen siendo el de menor tamaño.


### 5.6.1. Evaluación de supuestos de regresión lineal

#### 5.6.1.1. Parcelas de diagnóstico

A continuación, se detallará los supuestos de linealidad por medio de parcelas de diagnóstico, además se analizará los valores influyentes con respecto al modelo de regresión por medio de curvas Cook.

##### 5.6.1.1.1. Gráficos de diagnóstico para la validación del supuesto de linealidad







**Figura. 40** Parcelas de diagnóstico de linealidad aplicadas a MO.  
Elaborado por: Quintana J, Tituaña K, (2019)

En las anteriores graficas se puede apreciar que las nubes de puntos de los residuos están distribuidas linealmente en la recta de regresión de tal manera que se cumple el supuesto de linealidad.

#### 5.6.1.1.2. Gráficos de diagnóstico para el análisis de valores influyentes





**Figura. 41** Parcelas Cook para análisis de valores atípicos para MO.  
Elaborado por: Quintana J, Tituaña K, (2019)

El análisis de las gráficas presentas se puede observar que para los 5 modelos con sus respectivas variables NDVI, GNDVI, NDRE, NDWI y SMI no hay la presencia de valores atípicos; en caso de haber se debería excluirlos y comprobar su validez del modelo.

### 5.6.1.2. Pruebas de diagnostico

Las pruebas de diagnóstico presentadas a continuación son pruebas que nos van a confirmar los supuestos presentados en el ítem anterior.

**Tabla 15** Pruebas de diagnóstico de supuestos de regresión para MO.

Variable independiente del MRL	Pruebas de diagnóstico de supuestos					
	<i>Durbin Watson</i>		<i>Shapiro Wilk</i>		<i>Breusch-Pagan</i>	
	<i>DW</i>	<i>p-value</i>	<i>W</i>	<i>p-value</i>	<i>BP</i>	<i>p-value</i>
NDVI	1.651	0.146	0.986	0.957	0.0 95	0. 758
GNDVI	2.086	0.558	0.958	0.275	0.5 35	0. 464
NDRE	1.736	0.199	0.976	0.716	0.4	0.

					61	497
NDWI	1.661	0.148	0.977	0.739	0.1	0.
					30	719
SMI	1.657	0.149	0.970	0.546	0.2	0.
					44	621

Elaborado por: Quintana J, Tituaña K, (2019)

Una vez realizado el análisis de las gráficas de supuestos se emplean las pruebas de verificación para normalidad, homocedasticidad e independencia por medio de los test de Shapiro Wilk, Breusch-Pagan y Durbin Warson respectivamente. Los valores obtenidos en la *tabla 15* verifican los supuestos de la regresión lineal presentados, donde se afirma la normalidad de los datos por tener un p valor >0.05, la independencia de datos entre 1.5 y 2 y la homoscedasticidad confirmada con un p-value > 0.05.

#### 5.6.1.2.1. Selección y validación del mejor modelo

Por medio de la implementación de una validación cruzada K-fold y el criterio de selección de modelo Akaike se determinan los siguientes modelos como óptimos en relación a la variable dependiente materia orgánica.

**Tabla 16** Valores de validación cruzada y criterio Akaike para MO.

Variable independiente del MRL	Selección del mejor modelo	Validación cruzada K-fold		
	<i>Criterio AIC</i>	<i>RSME</i>	<i>R<sup>2</sup></i>	<i>MAE</i>
NDVI	55.131	0.478	0.669	0.417
GNDVI	54.783	0.554	0.805	0.490
NDRE	53.137	0.550	0.830	0.466
NDWI	54.031	0.532	0.814	0.491
SMI	54.284	0.535	0.662	0.465

Elaborado por: Quintana J, Tituaña K, (2019)


Como podemos observar en la *tabla 16* se confirma por medio del criterio AIC que el mejor modelo es NDRE siendo un índice de vegetación preciso. Por otra parte, el valor de validación K-fold sigue confirmando lo anterior mencionado por medio del análisis de  $R^2$  significativo de 0.83 y un error cuadrático medio de 0.55, con



respecto a los valores estrambóticos que presentan el RSME y el MAE para cada uno de los índices serán analizados en la discusión.

### 5.6.2. Predicción de los modelos de regresión

Con ayuda del software R studio generamos la gráfica con el comando “ggplot” de intervalos de predicción para el modelo más óptimo NDRE, obtenido en la etapa de selección y validación. En la *figura 41* podemos observar la representación de la banda de intervalos de confianza y de predicción donde se muestra que los datos tienen una distribución lineal y no presentan datos atípicos influyentes en el modelo.



**Figura. 42** Gráficos de predicción de Materia Orgánica vs NDRE.  
Elaborado por: Quintana J, Tituaña K, (2019)

### 5.6.3. Ecuaciones de MRL para estimación de contenido de MO

**Tabla 17** .Ecuaciones para la estimación de MO.

Índice	Ecuación	$R^2$	AIC
NDVI	$Y = 2.3404 + 5.7671 * NDVI$	0.5106	55.131
GNDVI	$Y = 1.9028 + 7.2856 * GNDVI$	0.5162	54.783
NDRE	$Y = 2.2506 + 9.0231 * NDRE$	0.5420	53.137
NDWI	$Y = 2.0033 + 7.3756 * NDWI$	0.5282	54.031
SMI	$Y = -7.7190 + 13.3445 * SMI$	0.5242	54.284

Elaborado por: Quintana J, Tituaña K, (2019)

Siendo la ecuación del índice NDRE la más óptima y ajustada a los datos observados.

### 5.7. MRL para la estimación de contenido de fósforo

Una vez generados los modelos con el comando “lm” del Software R studio y la obtención de los estadísticos primordiales de regresión por medio del comando summary se presentan en las siguientes tablas.

**Tabla 18** Resumen estadístico del modelo de regresión de P.

Variable independiente del MRL	Coeficientes de importancia			
	$\beta_0$	$\beta_1$	$Pr(> t )$ $\beta_0$	$Pr(> t )$ $\beta_1$
NDVI	21.1452	14.2904	< 2e-16	1.38e-08
GNDVI	20.8261	14.7149	< 2e-16	3.54e-05
NDRE	21.5017	18.4082	< 2e-16	1.48e-05
NDWI	21.0386	14.8527	< 2e-16	2.91e-05
SMI	2.83	25.25	0.562592	0.00013
				1

Elaborado por: Quintana J, Tituaña K, (2019)

**Tabla 19** Resumen de bondad y ajuste de modelo de regresión de P.

Variable independiente del MRL	Bondad de ajuste del modelo de regresión			
	<i>RSE</i>	<i>R2</i>	$R^2$ <i>ajustado</i>	<i>p-value</i>
NDVI	0.9983	0.6893	0.6782	1.384e-08
GNDVI	1.313	0.4627	0.4435	3.543e-05
NDRE	1.274	0.4942	0.4761	1.478e-05
NDWI	1.304	0.47	0.451	2.909e-05
SMI	1.373	0.4121	0.3911	0.000131
				4

Elaborado por: Quintana J, Tituaña K, (2019)

Analizando los resultados del summary de regresión podemos apreciar que el modelo que se ajusta de acuerdo a los valores estadísticos es el NDVI , el mismo que contiene un p-value de acuerdo a los coeficiente de importancia de 1.38 e-08, y un  $R^2$  ajustado de 0.6782 siendo el más significativo.


### 5.7.1. Evaluación de supuestos de regresión lineal


La evaluación se llevó a cabo mediante gráficas y pruebas de diagnóstico.

#### 5.7.1.1. Parcelas de diagnóstico

Para realizar un análisis de residuales del modelo se generaron las parcelas de diagnóstico, las cuales se presentarán a continuación como resumen las gráficas de linealidad y valores influyentes para cada uno de los índices o variables independientes.

##### 5.7.1.1.1. Gráficos de diagnóstico de linealidad residual






**Figura. 43** Parcelas de linealidad de supuestos para MRL de P.  
Elaborado por: Quintana J, Tituaña K, (2019)

En las figuras presentadas se observa la linealidad entre los supuestos residuales que se debe satisfacer en el modelo. También se debe cumplir distribución normal, homoscedasticidad y valores atípicos lo cuales se van analizar por diferentes test presentados posteriormente.

#### 5.7.1.1.2. Graficas de diagnóstico valores influyentes de MRL

Una de las parcelas de diagnóstico de residuos más común es la de puntos influyentes del modelo, la cual se presenta a continuación, para cada una de las variables regresivas.



**Figura. 44** Parcelas de puntos influyentes del modelo de regresión para P.  
Elaborado por: Quintana J, Tituaña K, (2019)

Por medio de las figuras se determina que no hay presencia de datos atípicos extremos en ningún modelo de regresión lineal para las variables independientes NDVI, GNDVI, NDWI, NDRE Y SMI.

### 5.7.1.2. Pruebas de diagnostico

Por medio del test de Shapiro Wilk, Durbin Watson y Breusch-Pagan se procede a verificar la independencia de datos, distribución normal de residuales y homoscedasticidad.

**Tabla 20** Pruebas de diagnóstico de supuestos de regresión para P.

Variable independiente del MRL	Pruebas de diagnóstico de supuestos					
	<i>Durbin Watson</i>		<i>Shapiro Wilk</i>		<i>Breusch-Pagan</i>	
	<i>DW</i>	<i>p-value</i>	<i>W</i>	<i>p-value</i>	<i>BP</i>	<i>p-value</i>
NDVI	1.634	0.135	0.979	0.796	0.950	0.330
GNDVI	2.281	0.756	0.969	0.499	0.084	0.772
NDRE	1.997	0.457	0.983	0.889	0.010	0.919
NDWI	1.886	0.341	0.956	0.250	1.706	0.192
SMI	1.619	0.125	0.967	0.451	1.001	0.315

Elaborado por: Quintana J, Tituaña K, (2019)

El test de Durbin-Watson nos permite conocer la linealidad por oscilar entre 1.5-2.5, Shapiro test nos confirma la distribución normal de los datos por tener p-value >0.05 por último Breusch-Pagan test determina la homoscedasticidad de los residuales por tener p-value >0.05.

### 5.7.2. Selección y validación del mejor modelo

Para realizar el proceso de validación y elección de modelo procedemos a emplear el criterio AIC y una validación cruzada K-fold con la finalidad de elegir el mejor.

**Tabla 21** Valores de validación cruzada y criterio Akaike para P.


Variable independiente del MRL	Selección del mejor modelo <i>Criterio AIC</i>	Validación cruzada K-fold		
		<i>RSME</i>	<i>R2</i>	<i>MAE</i>
NDVI	88.962	0.986	0.779	0.817
GNDVI	105.398	1.195	0.660	0.492
NDRE	103.586	1.251	0.712	1.058
NDWI	104.990	1.245	0.763	1.087
SMI	108.098	1.288	0.470	1.107

Elaborado por: Quintana J, Tituaña K, (2019)

En la *tabla 21* presentada podemos corroborar que el mejor modelo ajustado a los datos de fósforo es el de NDVI con un AIC de 88.962 de igual forma con RSM,  $R^2$  y MAE adecuados.

### 5.7.3. Predicción de los modelos de regresión

Con la ayuda de el comando de ploteo “ggpplot” generamos una figura de predictores que nos permite determinar la linealidad de la distribución de la nube de puntos y la escasez de puntos influyentes en el modelo.



**Figura. 45** Gráficos de predicción de P vs NDVI.

Elaborado por: Quintana J, Tituaña K, (2019)

### 5.7.4. Ecuaciones de MRL para la obtención de fósforo

**Tabla 22** Ecuaciones para la estimación de P.

Índice	Ecuación	$R^2$	AIC
NDVI	$Y = 21.1452 + 14.2904 * NDVI$	0.6782	88.962
GNDVI	$Y = 20.8261 + 14.7149 * GNDVI$	0.4435	105.398

NDRE	$Y = 21.5017 + 18.4082 * NDRE$	0.4761	103.586
NDWI	$Y = 21.0356 + 14.8527 * NDWI$	0.451	104.990
SMI	$Y = -2.8304 + 25.2535 * SMI$	0.3911	108.099

Elaborado por: Quintana J, Tituaña K, (2019)

### 5.8. MRL para la valoración de contenido de humedad

Se diseñaron de igual forma 5 modelos con las variables regresivas de la *tabla 23*, de igual manera se aplicó la función “lm” para realizar las regresiones y se obtuvo por medio del comando summary los resúmenes estadísticos para cada uno de los MRL.

**Tabla 23** Resumen estadístico de coeficientes del MRL humedad

Variable independiente del MRL	Coeficientes de importancia			
	$\beta_0$	$\beta_1$	$Pr(> t )$ $\beta_0$	$Pr(> t )$ $\beta_1$
NDVI	25.659	29.674	2.69e-15	0.000217
GNDVI	22.766	40.284	6.13e-12	4.14e-05
NDRE	26.082	40.392	1.93e-14	0.00129
NDWI	22.368	45.266	1.09e-13	1.20e-06
SMI	-47.531	93.989	7.07e-06	5.64e-10

Elaborado por: Quintana J, Tituaña K, (2019)

**Tabla 24** Resumen estadístico de la bondad de ajuste del MRL– humedad

Variable independiente del MRL	Bondad de ajuste del MRL			
	<i>RSE</i>	<i>R2</i>	<i>R2 ajustado</i>	<i>p-value</i>
NDVI	3.848	0.3916	0.369	0.0002168
GNDVI	3.636	0.4569	0.437	4.14e-05
NDRE	4.088	0.3135	0.289	0.001294
NDWI	3.216	0.5751	0.56	1.202e-06
SMI	2.457	0.7521	0.7433	5.641e-10

Elaborado por: Quintana J, Tituaña K, (2019)


Como se observa en la *tabla 24*, tres de los índices poseen una buena significancia estadística en sus pendientes e intersecciones, mientras que dos de ellos presentan un valor medio en su p value. Con respecto a la precisión del modelo se puede observar que el mayor R2 ajustado es del 0,7433 y el menor de 0,289 esto se puede corroborar con su RSE donde el primero posee 2.457 y el segundo 4.088.




### 5.8.1. Evaluación de los supuestos de regresión lineal

Con la finalidad de los MRL sean verosímiles estos deben cumplir con los supuestos de regresión para lo cual se evaluará la linealidad y valores influyentes de los mismos por medio de un gráfico de diagnóstico, los restantes supuestos serán evaluados mediante las mismas pruebas, que fueron ejecutadas en las anteriores secciones.

#### 5.8.1.1.1. Gráficos de diagnóstico para la validación de linealidad de los modelos.







**Figura. 46** Gráficas de linealidad para los modelos de estudio para humedad  
Elaborado por: Quintana J, Tituaña K, (2019)

En los gráficos anteriores se puede apreciar que todos los modelos implementados en este estudio para la determinación de humedad cumplen con el supuesto de linealidad, tal como se puede observar con la distribución de la nube de puntos a través de la línea de regresión.

#### 5.8.1.1.2. Gráficos de diagnóstico para evaluar valores influyentes de los modelos.





**Figura. 47** Gráficas de distancia Cook para los modelos de estudio para la humedad  
Elaborado por: Quintana J, Tituaña K, (2019)

En los primeros cuatro gráficos anteriores se puede evidenciar que en no existe ningún valor atípico que sobrepasen las líneas de aplacamiento, en cambio el ultimo gráfico presentar un punto influyente mismo que tampoco sobrepasa los 0.5 de distancia por lo tanto este no puede poseer una influencia significativamente grande que pueda afectar en el modelo.

### 5.8.1.2. Pruebas de diagnostico

En este apartado se evaluaron los supuestos de normalidad, homoscedasticidad e independencia para cada uno de los modelos de regresión diseñados. El resumen de la evaluación se presenta en la siguiente tabla.

**Tabla 25** Pruebas de diagnóstico para supuestos de regresión para humedad.

Variable independiente del MRL	Pruebas de diagnóstico de supuestos					
	<i>Durbin Watson</i>		<i>Shapiro Wilk</i>		<i>Breusch-Pagan</i>	
	<i>DW</i>	<i>p-value</i>	<i>W</i>	<i>p-value</i>	<i>BP</i>	<i>p-value</i>
NDVI	1.5104	0.07186	0.95628	0.2482	3.4797	0.06212
GNDVI	1.8382	0.2915	0.94013	0.0917	3.1128	0.0777
NDRE	1.6653	0.148	0.96302	0.3690	2.2341	0.1350
NDWI	1.8412	0.2953	0.9726	0.6119	0.1689	0.6811
SMI	1.6692	0.157	0.97964	0.8158	0.9432	0.3315

Elaborado por: Quintana J, Tituaña K, (2019)

Según los resultados obtenidos de la tabla anterior todos los modelos de regresión cumplen con el supuesto de normalidad ya que su *p value* es mayor a 0.05 descartándose su *H1* de distribución no normal, también estos cumplen con la homogeneidad de varianza con respecto a los residuos ya que de igual forma su *p value* es mayor a 0.05 donde se descarta la *H1* de que los datos no son homoscedasticos finalmente con el test de Durbin se establece que los residuos poseen independencia ya que están dentro del rango de 1.5 a 2.5 (Bouza-Herrera, 2018).

### 5.8.1.3. Selección y validación del mejor modelo

Se empleó el criterio de AIC y validación K-Fold para seleccionar el mejor modelo.

**Tabla 26** Selección y validación del mejor modelo para humedad.

Variable independiente del MRL	Selección del mejor modelo <i>Criterio AIC</i>	Validación cruzada K-fold		
		<i>RSM E</i>	<i>R2</i>	<i>MAE</i>
NDVI	169.9271	3.719064	0.6566324	3.330959
GNDVI	166.5227	3.325161	0.7202131	2.944345
NDRE	173.5522	4.003903	0.6828571	3.386967
NDWI	159.1562	3.064	0.7837825	2.5842


		944		48
		2.203		1.9385
SMI	142.9937	097	0.9052044	26

Elaborado por: Quintana J, Tituaña K, (2019)

El modelo que mejor se ajusta para estimar el contenido de humedad es el del SMI, ya que presente un  $R^2$  de predicción de 0.952.

#### 5.8.1.4. Intervalos de predicción y confianza de los modelos

A continuación, se presenta por medio de gráficas los intervalos de predicción y confianza para el mejor modelo propuesto para estimar el contenido de humedad.



**Figura. 48** De izquierda a derecha: grafico de predicción de humedad con respecto al SMI y grafico de humedad conocida y simulada

Elaborado por: Quintana J, Tituaña K, (2019)

En la figura de la izquierda se puede observar la distribución de los valores predichos alrededor de la recta de regresión la cual está delimitada por la banda de confianza de color gris y la banda de predicción de color rojo, de igual forma la figura inferior indica la distribución de los valores predichos sobre los observados.

#### 5.8.2. Ecuaciones de MRL para la estimación de humedad

**Tabla 27** Ecuaciones planteadas para determinación de humedad

Índice	Ecuación	$R^2$ ajustado	AIC
NDVI	$Y = 25.6595 + 26.67419 \text{ NDVI}$	0.3916	169.9271
GNDVI	$Y = 22.76641 + 40.28373 \text{ GNDVI}$	0.4569	166.5227

NDRE	$Y = 26.0821 + 40.391 \text{ NDRE}$	0.3135	173.5522
NDWI	$Y = 22.368 + 45.2665 \text{ NDWI}$	0.5751	159.1562
SMI	$Y = -47.5311 + 93.9886 \text{ SMI}$	0.7521	142.9937


---

Elaborado por: Quintana J, Tituaña K, (2019)

La ecuación que mejor se ajusta para estimar el contenido de humedad es el SMI con un  $R^2$  ajustado de 0.7521.


### **5.9. Mapas de estimación de parámetros**

Empleando la opción de calculadora raster del software de ArcGIS se diseñaron diversos mapas de estimación para cada uno de los parámetros estudiados: nitrógeno, materia orgánica, fósforo y humedad utilizando las ecuaciones más optimas de predicción para el mes de abril.




**Figura. 49** Mapa de estimación de nitrógeno total MRL-GNDVI-A1






**Figura. 50** Mapa de estimación de nitrógeno total MRL-GNDVI-A2






**Figura. 51** Mapa de estimación de materia orgánica MRL-NDRE-A1




**Figura. 52** Mapa de estimación de materia orgánica MRL-NDRE-A2






**Figura. 53** Mapa de estimación de contenido de fósforo MRL-NDVI-A1




**Figura. 54** Mapa de estimación de contenido de fósforo MRL-NDVI-A2





**Figura. 55** Mapa de estimación de humedad MRL-SMI-A1



**Figura. 56** Mapa de estimación de humedad MRL-SMI-A2

### 5.10. Discusión general

En la actualidad la detección remota es una de las técnicas más utilizadas por el aumento de pérdida de calidad de suelo (Y. Wang et al., 2016), donde el uso de índices espectrales para estimar el rendimiento de los cultivos puede ser relacionada con su salud (Moges et al., 2005). Se comprobó que los índices espectrales utilizados en este estudio se encuentran vinculados fuertemente a la estimación del contenido de nitrógeno (ECN) y humedad, mientras que para la materia orgánica y el fósforo no existe una relación considerable.

Se diseñó un MRL donde se asume que los factores del suelo y el ambiente son lineales; de los modelos generados para la estimación de los parámetros mencionados el GNDVI es el que más correlación presenta con el N esto se debe a que la banda verde posee un punto de saturación mayor, lo que lo hace más sensible a la actividad fotosintética, consumo de agua y cantidad de nitrógeno (Kharuf et al., 2018), los resultados obtenidos concuerdan con (Sripada, Schmidt, Dellinger, & Beegle, 2008) que presenta un  $R^2$  *adj.* de 0.79 lo que se asemeja al calculado de 0.7958, el índice de NDRE al trabajar con la banda de borde rojo también lo vuelve sensible a los cambios de nitrógeno (Barnes et al., 2000), por lo que se considera como la segunda opción de estimación, con un  $R^2$  *ajustado* de 0.7662 el cual es corroborado por el estudio de (Rodríguez et al., 2006) que presenta de 0.75 con 24 observaciones planteadas.

Al trabajar en dos áreas de estudios con plantaciones de balsa de edad mediana y avanzada, el índice de NDVI disminuye su precisión espectral ya que trabaja mejor en cultivo de etapa de crecimiento temprana (Xie et al., 2018), lo que no quiere decir que presente cierta desventaja en comparación con el GNDVI y NDRE (Moges et al., 2005).

La ECN ayuda a conocer las condiciones en las que se encuentra el suelo, ya que es un nutriente esencial para las plantas y su suficiente captación permite conseguir un alto rendimiento en los cultivos, la sobresaturación de este es causado por grandes problemas de fertilización por parte de los agricultores (H. Wang et al., 2019), además de que la temperatura y humedad facilitan la mineralización o inmovilización del nitrógeno, provocando un déficit fotosintético (M. Wang et al., 2012); por consiguiente una buena estimación de N permite aumentar la eficiencia de nutrientes en los sistemas de cultivo evitando así impactos negativos y fisiológicos en la vegetación.(Mary, Recous, Darwis, & Robin, 1996)

Un estudio realizado por (Liu et al., 2015) estima el contenido de materia orgánica por medio del índice de NDVI obteniendo un  $R^2_{adj.}$  de 0,27 mientras que en esta investigación, el mejor modelo que se correlaciona es el NDRE con un  $R^2_{adj.}$  de 0,5912 esto se debe a que el índice se ajusta mejor a las diferentes condiciones atmosféricas, el tipo de cultivo y etapa de crecimiento en que las áreas de estudio se encuentran. La erosión de la superficie del suelo está asociada a la pérdida de nutrientes y materia orgánica (Sainz & Echeverria, 2006), hay que indicar que en sitios cultivados la MO tiene una rápida caída por la falta de rotación de cultivos e intensificaciones agrícolas, provocando deterioros en el mismo, de tal forma que este parámetro facilita valorar su salud.

Uno de los parámetros físicos que influyen en la cantidad de MO en el suelo es el pH por afectar la disponibilidad de nutrientes ya que los  $H^+$  desplazan a estos e impiden su disolución, acidificando el suelo (Jones, Olson-rutz, & McCauley, 2017). Por otra parte, analizando los resultados experimentales de los cultivos de balsa el pH promedio es de 6.76, lo que indica una distribución adecuada de nutrientes, esto



es respaldado con los análisis de laboratorio realizados que manifiestan un nivel de MO está en un rango medio.

La humedad promedio obtenida en el suelo de las plantaciones de balsa es de 0,32 indicando una captación de agua alta, favorecida por el clima mega térmico humeado que contiene elevadas precipitaciones en los meses de estudio, la mejor relación que se encontró para estimar este parámetro es el SMI el cual presenta un *R2 ajustado* del 0,7521 el cual es respaldado por un RSME de 2.2031 obtenido en una validación cruzada K-Flod; el estudio de (Boudewijn, 2015) de estimación continua de humedad el suelo emplea el mismo índice donde tiene un  $R^2$  de 0,5771, en el cual se indica que se puede estimar con éxito la humedad del suelo, empleando el soil moisture index.

Así que la humedad del suelo es un parámetro óptimo para emplear como indicador de sequía. Se considera también que el NDWI y el GNDVI muestran, sensibilidad frente a los cambios de humedad del suelo y están extramente relacionados a la falta de agua en la vegetación, dicho lo anterior se obtiene en el análisis una de estimación del 0,5751 y 0,4569 de bondad de ajuste esto puede acercarse a los resultados obtenidos de (Rokni, Ahmad, Selamat, & Hazini, 2014) que tiene un 0,72 empleando una vegetación homogénea.

Este estudio obtuvo una buena correlación positiva del fósforo con respecto al NDVI de 0,6782, el resultado obtenido se debe a la relación existente del índice y el parámetro mencionado con el nitrógeno y el contenido clorofílico de las plantas (Rivero, Grunwald, Binford, & Osborne, 2009), la investigación de (Sembiring et al., 1998), empleó el NDVI para estimar la predicción y captación de fósforo del suelo, mencionando que este parámetro puede ser un buen indicador de fertilidad y calidad del mismo.

Predecir 4 parámetros del suelo no es suficiente para tener una idea a profundidad del estado general del mismo ya que este es un conjunto de materia orgánica, inorgánica, aire y agua formado por varios horizontes, de tal manera que este estudio se enfoca a los requerimientos nutricionales del suelo que influyen sobre el desarrollo de los cultivos, así como para la identificación de erosión del suelo, estrés hídrico y sobresaturación por uso excesivo de productos nitrogenados y fosforados que pueden ser estimados por medio del empleo de índices espectrales.

Una vez analizados los resultados obtenidos, es importante comprobar el rendimiento de estos en otras condiciones físicas y tipos de cultivos con la finalidad de extender la aplicación de estos medios, para ahorrar recursos, mejorar la producción sin la necesidad de que se cree una alteración significativa en el suelo y el ecosistema, lo que pueda generar una disminución en calidad y salud.

## 6. CONCLUSIONES Y RECOMENDACIONES

### 6.1. Conclusiones

El UAV permite recopilar imágenes precisas de varias hectáreas de cultivos en tiempo real, las cuales, al ser sometida a un proceso de análisis digital por softwares informáticos, se obtiene información importante de las condiciones existentes en la zona, mismos que combinándolos con algoritmos matemáticos y el cálculo de índices se puede predecir el estado nutricional y rendimiento del terreno.

Es así que se demostró que el uso de sensores remotos permite la estimación de parámetros de calidad del suelo, principalmente en nitrógeno y humedad, con los índices de GNDVI y SMI, sin embargo, el NDVI tanto como el NDRE posibilitan la apreciación de fósforo y materia orgánica respectivamente.

Como resultado la relación entre las variables (N, P, MO y humedad), están estrechamente sujetas a los requerimientos nutricionales del suelo, donde un exceso o déficit de uno de ellos puede alterar a los demás produciéndose cambios relevantes en su composición llegado a sobresaturarlo, erosionarlo o causando etapas de estrés, para lo cual conjuntamente con el apoyo del uso de índices espectrales se puede estimar cada uno de los parámetros mencionados y prevenir la aparición de las anomalías antedichas, llegado a este punto se valida la hipótesis planteada en la *sección 4.3.1*.

De modo que el uso de mapas de estimación de N y P se puede emplear para recuperación y mejora de suelos por sobresaturación de los mismos dado por el uso excesivo de fertilizantes, que provocan, pérdidas de fertilidad y contaminación al medio ambiente, por otra parte, estar al tanto del contenido de materia orgánica y

humedad de un terreno puede ayudar a prevenir procesos erosivos, y de estrés hídrico.

## **6.2. Recomendaciones**

Para evitar sesgos de precisión en la captura de imágenes y daños al equipo (UAV) hay que considerar varios factores como son: velocidad de viento, tiempo climático, temperatura, altitud, cobertura vegetal y zona de amortiguamiento.

Para obtener resultados eficaces en los índices NDVI, GNDVI y NDRE hay que tomar en cuenta la etapa de crecimiento del cultivo, ya que la reflectancia propiciada por cada uno de ellos es diferente de tal manera que el NDVI trabaja mejor en campos con baja densidad de biomasa y durante los primeros meses y etapa intermedia de siembra, mientras que los dos restantes, desempeñan mejores resultados en fase intermedia y avanzada de labranza.

En respecto al índice humedad del suelo SMI, hay que considerar la temperatura superficial del terreno, por lo cual es importante realizar la obtención de imágenes en un tiempo con alta radiación solar.

Se recomienda fomentar el uso de UAV como alternativa para recuperación y mejora de terrenos por su facilidad de manejo, rapidez en el procesamiento de información y ahorro de recursos.

Se recomienda la aplicación de otros parámetros de calidad del suelo e índices espectrales para consolidar la aplicación de este tipo de tecnologías en el recurso suelo y poder determinar su estado y salud a mayor escala.

## 7. BIBLIOGRAFÍA

- AGROCALIDAD. (2015). Instructivo Muestreo Suelos-Laboratorios-Agrocalidad. Recuperado de <http://www.agrocalidad.gob.ec/wp-content/uploads/pdf/laboratorios/suelos-foliares-aguas/instructivo-muestreo-suelos-laboratorios-agrocalidad.pdf>
- Alcaraz, D. (2014). Cambios En La Diversidad De Especies Sobre El Servicio Ecosistémico De Captura. <https://doi.org/10.13140/2.1.1026.1124>
- Altman, D., & Bland, M. (2005). Standard deviations and standard errors. *BMJ*, 331(7521), 903. <https://doi.org/10.1136/bmj.331.7521.903>
- Ammour, N., Alhichri, H., Bazi, Y., Benjdira, B., Alajlan, N., & Zuair, M. (2017). Deep Learning Approach for Car Detection in UAV Imagery. *Remote Sensing*, 9(4), 312. <https://doi.org/10.3390/rs9040312>
- Ariza Ortiz, A., Roa Melgarejo, O. J., Serrato, P. K., & León Rincón, H. A. (2018). Uso de índices espectrales derivados de sensores remotos para la caracterización geomorfológica en zonas insulares del Caribe colombiano. *Perspectiva Geográfica*, 23(1), 105-122. <https://doi.org/10.19053/01233769.5863>
- Bai, Z., Creamer, R. E., Brussaard, L., Sukkel, W., de Goede, R., Pulleman, M., ... Bünemann, E. K. (2018). Soil quality – A critical review. *Soil Biology and Biochemistry*, 120(February), 105-125. <https://doi.org/10.1016/j.soilbio.2018.01.030>
- Barnes, E. M., Clarke, T. R., Richards, S. E., & Colaizzi, P. D. (2000). Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. *Precision Agriculture Center, University of Minnesota*, 37(5), [CD Rom], Proceedings of the Fifth International C. Recuperado de

<http://www.sciencedirect.com/science/article/B6V03-4XPB6WG-4/2/e3842d0d34d1460977c698f1bb31d99a>

Bini, C. (Ed. . (2010). *Fron Soil Contamination to Land Restoration*.

Björklund, P. A., & Mello, F. V. (2012). *Soil organic matter: ecology, environmental impact and management*. Nova Science Publishers.

Boudewijn, L. (2015). GIS workflow for continuous soil moisture estimation based on medium resolution satellite data. *AGILE 2015 – Lisbon, June 9-12*.

Bouza-Herrera, C. N. (2018). *MODELOS DE REGRESIÓN Y SUS APLICACIONES*.

La Habana: GRASHUMEDIA. Recuperado de [https://www.researchgate.net/publication/323227561\\_MODELOS\\_DE\\_REGRESION\\_Y\\_SUS\\_APLICACIONES](https://www.researchgate.net/publication/323227561_MODELOS_DE_REGRESION_Y_SUS_APLICACIONES)

Conapa. (2017). Cámara thermo Map. Recuperado de [http://www.innovarioja.tv/docs/1624/Javier\\_Santiago.pdf](http://www.innovarioja.tv/docs/1624/Javier_Santiago.pdf)

Conklin, A. (2013). *Introduction to Soil Chemistry*. Canada: Wiley Blackwell.

Escolano, U. (2015). *Sistemas de información geográfica: una introducción para estudiantes de geografía*. (Prensas de la Universidad de Zaragoza, Ed.).

Zaragoza. Recuperado de <https://bibliotecas.ups.edu.ec:2708/lib/bibliotecaupssp/reader.action?docID=5214004&query=sistemas+de+informacion+geografica+#>

Everaerts, J. (2008). THE USE OF UNMANNED AERIAL VEHICLES (UAVS) FOR REMOTE SENSING AND MAPPING. Recuperado de [www.aerobel.be](http://www.aerobel.be)

Finn, M. ., & Reed, M. . (2012). *A Straight Forward Guide for Processing Radiance and Reflectance for EO-1 ALI, Landsat 5 TM, Landsat 7 ETM+, and ASTER*.

- Recuperado de [https://semiautomaticclassificationmanual-v5.readthedocs.io/es/latest/remote\\_sensing.html](https://semiautomaticclassificationmanual-v5.readthedocs.io/es/latest/remote_sensing.html)
- Fox, J. (2002). car package for R. Recuperado 30 de abril de 2019, de <https://www.rdocumentation.org/packages/car/versions/1.2-16>
- Franzmeier, D. P., McFee, W. W., & Helmut, K. (2016). *Soil Science Simplified*. (Waveland Press, Ed.) (Sixth). Canada.
- Gandhi, G. M., Parthiban, S., Thummalu, N., & Christy, A. (2015). Ndvi: Vegetation Change Detection Using Remote Sensing and Gis - A Case Study of Vellore District. *Procedia Computer Science*, 57, 1199-1210. <https://doi.org/10.1016/j.procs.2015.07.415>
- Garrett, G., & Hadley, W. (2017). *R for Data Science* (O'REILLY). Recuperado de <https://r4ds.had.co.nz/index.html>
- Garwood, N., & Lighthton, J. (1996). Generalidade de la Ochroma pyramidale. *Repertorium Specierum Novarum Regni Vegetabilis.*, 5(123), 66-68.
- Hillel, D. (2004). *INTRODUCTION TO ENVIRONMENTAL SOIL PHYSICS*. Massachusetts: Elsevier Science.
- IEE, E. (2013). Generación de geoinformación para la gestión del territorio a nivel nacional, escala 1: 25 000 - clima e hidrología, 21. <https://doi.org/10.1017/CBO9781107415324.004>
- INAMHI. (2017). Tipos de climas Ecuador 2017. Recuperado de [http://www.serviciometeorologico.gob.ec/gisweb/TIPO\\_DE\\_CLIMAS/PDF/TIP OS DE CLIMA ECUADOR 2017.pdf](http://www.serviciometeorologico.gob.ec/gisweb/TIPO_DE_CLIMAS/PDF/TIP OS DE CLIMA ECUADOR 2017.pdf)
- ISO 11464. (2006). INTERNATIONAL STANDARD Soil quality — Pretreatment

of samples for physico-chemical analysis, 2006.

ISO 18400. (2018). ISO 18400- 104 Soil quality -- Sampling.

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning*. (Springer, Ed.) (Primera, Vol. 103). New York.  
<https://doi.org/10.1007/978-1-4614-7138-7>

Jones, C., Olson-rutz, K., & McCauley, A. (2017). NUTRIENT MANAGEMENT CCA 1.0 NM 0.5 SWM CEU Soil pH and Organic Matter. *Soil pH and Organic Matter*, (8), 1-16. Recuperado de <http://landresources.montana.edu/nm/documents/NM8.pdf>

Kassambara, A. (2018a). Cross-Validation Essentials in R - Articles - STHDA. Recuperado 10 de mayo de 2019, de <http://www.sthda.com/english/articles/38-regression-model-validation/157-cross-validation-essentials-in-r/#example-of-data>

Kassambara, A. (2018b). Linear Regression Assumptions and Diagnostics in R: Essentials - Articles - STHDA. Recuperado 13 de mayo de 2019, de <http://www.sthda.com/english/articles/39-regression-model-diagnostics/161-linear-regression-assumptions-and-diagnostics-in-r-essentials/>

Kassambara, A. (2018c). Regression Model Accuracy Metrics: R-square, AIC, BIC, Cp and more - Articles - STHDA. Recuperado 28 de mayo de 2019, de <http://www.sthda.com/english/articles/38-regression-model-validation/158-regression-model-accuracy-metrics-r-square-aic-bic-cp-and-more/>

Kharuf, S., Orozco, R., Díaz, O., & Pineda, E. (2018). Multispectral aerial image processing system for precision agriculture. *Sistemas y Telemática*, 16(47), 45-



58. <https://doi.org/10.18046/syt.v16i47.3221>

Laguna, C. (2009). Correlación Y Regresión Lineal. *Instituto Aragonés De Ciencia De La Salud*, 1-18.

Liu, S., An, N., Yang, J., Dong, S., Wang, C., & Yin, Y. (2015). Prediction of soil organic matter variability associated with different land use types in mountainous landscape in southwestern Yunnan province, China. *Catena*, 133, 137-144. <https://doi.org/10.1016/j.catena.2015.05.010>

Madariaga, F., González, J. L., & Rodríguez, M. (2013). Inferencia estadística Módulo de regresión lineal simple, (147), 57.

Mary, B., Recous, S., Darwis, D., & Robin, D. (1996). Interactions between decomposition of plant residues and nitrogen cycling in soil. *Plant and Soil*, 181(1), 71-82. <https://doi.org/10.1007/BF00011294>

McKean, S. (1993). Manual de análisis de suelos y tejido vegetal. *Centro internacional de agricultura tropical (CIAT)*, 19(2), 133-173. <https://doi.org/10.1163/15733823-00192P02>

Mendoza, R., & Espinoza, A. (2017). Guía Técnica para muestreo de suelos. ASA, 13-21. Recuperado de <http://repositorio.una.edu.ni/3613/1/P33M539.pdf>

Moges, S. M., Raun, W. R., Mullen, R. W., Freeman, K. W., Johnson, G. V., & Solie, J. B. (2005). Evaluation of Green, Red, and Near Infrared Bands for Predicting Winter Wheat Biomass, Nitrogen Uptake, and Final Grain Yield. *Journal of Plant Nutrition*, 27(8), 1431-1441. <https://doi.org/10.1081/PLN-200025858>

Montgomery, D. C., Peck, E. A., & Vining, G. (2012). *Introduction to Linear*

*Regression Analysis*. (Wiley, Ed.) (5ta ed.). United States of America.

Muños Aguayo, P. (2013). Apuntes de Teledetección: Índices de vegetación Índices de vegetación, 15.

Navarro Garcia, G., & Navarro Blaya, S. (2003). *Química agrícola: el suelo y los elementos químicos esenciales para la vida vegetal* (2da ed.). Madrid: Ediciones Mundi-Prensa. <https://doi.org/M.37.112-2003>

Novales, A. (2010). Análisis de Regresión. *Departamento de Economía Cunitativa*. Recuperado de [https://www.ucm.es/data/cont/docs/518-2013-11-13-Analisis de Regresion.pdf](https://www.ucm.es/data/cont/docs/518-2013-11-13-Analisis%20de%20Regresion.pdf)

Paillacho, C. (2010). *Evaluación del crecimiento inicial de Eucalyptus urograndis, Gmelina arborea Roxb Y Ochroma pyramidale Cav bajo la aplicación de cuatro dosis de potasio en la hacienda Zoila Luz del cantón Santo Domingo*.

Paladino, M. (2017). Modelo lineales con R. Recuperado 14 de mayo de 2019, de [https://www.institutomora.edu.mx/testU/SitePages/martinpaladino/modelos\\_lineales\\_con\\_R.html?fbclid=IwAR3a0pngyaxWhKpbw7puXKqVaXJX1Jvp5kpi29oJtm3vCFsuxO7pUUROHE#homocedasticidad](https://www.institutomora.edu.mx/testU/SitePages/martinpaladino/modelos_lineales_con_R.html?fbclid=IwAR3a0pngyaxWhKpbw7puXKqVaXJX1Jvp5kpi29oJtm3vCFsuxO7pUUROHE#homocedasticidad).

Panreac. (2015). Determinación De Nitrógeno Por El Método Kjeldahl. *Itwreagent*, 12. Recuperado de [http://www.uv.es/gidprl/practica\\_Kjeldahl/index.html](http://www.uv.es/gidprl/practica_Kjeldahl/index.html)

Pardo Merino, A., & Ruiz Díaz, M. Á. (2001). Análisis de correlación lineal. Los procedimientos Correlaciones bivariadas y Correlaciones parciales. *SPSS 10. Guía para el análisis de datos.*, 323-335.

Paredes, J. A., Gonzalez, J., Saito, C., & Flores, A. (2017). Multispectral imaging system with UAV integration capabilities for crop analysis. *IEEE 1st*

*International Symposium on Geoscience and Remote Sensing, GRSS-CHILE*  
2017, (June). <https://doi.org/10.1109/GRSS-CHILE.2017.7996009>

Parrales, G. (2012). *ESTABLECIMIENTO DE PARCELAS DE Balsa (Ochroma pyramidale) CON LA APLICACIÓN DE CUATRO DOSIS DE RIEGO*". UNIVERSIDAD ESTATAL DEL SUR DE MANABÍ. Recuperado de <http://repositorio.unesum.edu.ec/bitstream/53000/120/1/PARRALES FIGUEROA GRISELDA CONCEPCIÓN.pdf>

Parrot SA. (2019). Cámara Parrot SEQUOIA+. Recuperado 24 de marzo de 2019, de <https://www.parrot.com/soluciones-business/profesional/parrot-sequoia#mejora-tu-rendimiento-agricola-ahorra>

Perez, A. M. (2015). Principios de bioestadística para comprender los resultados reportados en los artículos científicos. *Medigraphic*, 11(3), 91-95.

Pix4D. (2019). Support Pix4D. Recuperado 31 de marzo de 2019, de <https://support.pix4d.com/hc/en-us>

PLANTABAL S.A. (2015). *PLANTACIONES DE Balsa PLANTABAL S.A FASE I DIAGNOSTICO (Valencia)*. Valencia Los Rios.

Radojevic, M., & Bashkin, V. (2006). *Practical Environmental Analysis*. (Royal Society of Chemistry, Ed.) (Segunda, Vol. 84). Reino Unido.

Rawlings, J. O., Pantula, S. G., & Dickey, D. A. (1998). *Applied Regression Analysis: A Research Tool, Second Edition. Springer Texts in statistics* (Vol. 18). <https://doi.org/10.1007/b98890>

Reyna, T., Reyna, S., Lábaque, M., Fulginiti, F., Riha, C., & Linares, J. (2014). Importancia de la determinación de la humedad en estudios de infiltración y

escorrentía superficial para períodos largos, 9(12), 20.  
<https://doi.org/10.4136/1980-993X>

Rivero, R. G., Grunwald, S., Binford, M. W., & Osborne, T. Z. (2009). Integrating spectral indices into prediction models of soil phosphorus in a subtropical wetland. *Remote Sensing of Environment*, 113(11), 2389-2402.  
<https://doi.org/10.1016/J.RSE.2009.07.015>

Rodríguez, D., Fitzgerald, G. J., Belford, R., & Christensen, L. K. (2006). Detection of nitrogen deficiency in wheat from spectral reflectance indices and basic crop eco-physiological concepts. *Australian Journal of Agricultural Research*, 57(7), 781. <https://doi.org/10.1071/ar05361>

Rokni, K., Ahmad, A., Selamat, A., & Hazini, S. (2014). Water feature extraction and change detection using multitemporal landsat imagery. *Remote Sensing*, 6(5), 4173-4189. <https://doi.org/10.3390/rs6054173>

Rosete, F., & Bocco, G. (2009). *Los sistemas de información geográfica y la percepción remota: herramientas integradas para los planes de manejo en comunidades forestales*. (Instituto Nacional de Ecología, Ed.). Recuperado de <https://bibliotecas.ups.edu.ec:2708/lib/bibliotecaupssp/reader.action?docID=3181916&query=Sig&ppg=1>

Saha, A., Patil, M., Goyal, V. C., & Rathore, D. S. (2018). Assessment and Impact of Soil Moisture Index in Agricultural Drought Estimation Using Remote Sensing and GIS Techniques. *Proceedings*, 7(1), 8. <https://doi.org/10.3390/ecws-3-05802>

Sainz, H., & Echeverria, H. E. (2006). Niveles de materia organica y pH en suelos agricolas de la región pampena y extra pampeana Argentina. *Infomaciones*

*agronomicas*, (2).

Schjønning, P., Elmholt, S., & Christensen, B. . (Eds.). (2004). *Managing Soil Quality* (7th ed.). Londres: CABI Publishing.

Schloerke B. (2017). GGally: Extension to ggplot2. *R package version 1.4.0*.  
Recuperado de <https://cran.r-project.org/web/packages/GGally/index.html>

Seir, E. (2002). Comparison of Tests for Univariate Normality. *Journal of Statistical Computation and Simulation*, 42(1-2), 21-38.  
<https://doi.org/10.1080/00949659208811407>

Sembiring, H., Raun, W. R., Johnson, G. V., Stone, M. L., Solie, J. B., & Phillips, S. B. (1998). Detection of nitrogen and phosphorus nutrient status in winter wheat using spectral radiance. *Journal of Plant Nutrition*, 21(6), 1207-1233.  
<https://doi.org/10.1080/01904169809365478>

senseFly. (2018). eMotion 3 User manual, (March), 5-10; 73-75.

SenseFly. (2018). senseFly Camera Collection. Recuperado de  
<https://www.sensefly.com/app/uploads/2019/03/Camera-Collection-ES.pdf>

SenseFly. (2019). eBee Classic de senseFly. Recuperado 22 de marzo de 2019, de  
<https://www.sensefly.com/drone/ebec-mapping-drone/#>

Sequoia, P. (2016). Especificaciones Técnicas Parrot Sequoia. Recuperado de  
[http://www.uavsensefly.cl/PDF/Ficha\\_Tecnica\\_Sequoia\\_V2.pdf](http://www.uavsensefly.cl/PDF/Ficha_Tecnica_Sequoia_V2.pdf)

Spence, J. R., & Stanley, D. J. (2016). Prediction Interval: What to Expect When You're Expecting ... A Replication. *PLOS ONE*, 11(9), e0162874.  
<https://doi.org/10.1371/journal.pone.0162874>

- SPH. (2016). Regression Diagnostics. Recuperado 13 de mayo de 2019, de [http://sphweb.bumc.bu.edu/otlt/MPH-Modules/BS/R/R5\\_Correlation-Regression/R5\\_Correlation-Regression7.html](http://sphweb.bumc.bu.edu/otlt/MPH-Modules/BS/R/R5_Correlation-Regression/R5_Correlation-Regression7.html)
- Sripada, R., Schmidt, J., Dellinger, A., & Beegle, D. (2008). Evaluating Multiple Indices from a Canopy Reflectance Sensor to Estimate Corn N Requirements. *Agronomy Journal*, 100(6), 1553. <https://doi.org/10.2134/agronj2008.0017>
- Stanley, J. (2017). An Introduction to Tidyverse. *Handbook of Set-Theoretic Topology*, (7), 503-567. <https://doi.org/10.1016/b978-0-444-86580-9.50014-8>
- Strawn, D., Bohn, H., & O'Connor, G. (Eds.). (2015). *Soil Chemistry* (Fourth). UK: WileyBlackwell.
- Swalin, A. (2018). Choosing the Right Metric for Evaluating Machine Learning Models — Part 1. Recuperado 15 de mayo de 2019, de <https://medium.com/usf-msds/choosing-the-right-metric-for-machine-learning-models-part-1-a99d7d7414e4>
- SYSMAP. (2017). eBee El dron de cartografía profesional, 13.
- Szretter, E. M. (2017). Apunte de Regresión Lineal.
- Taiyun Wei, M., Taiyun Wei cre, A., Simko aut, V., Levy ctb, M., Xie ctb, Y., Jin ctb, Y., & Zemla ctb, J. (2017). *Package «corrplot» Title Visualization of a Correlation Matrix*.
- Torsten, H., & Achim, Z. (2019). lmtest: Testing Linear Regression Models. *R package lmtest version 0.9-37*. Recuperado de <https://cran.r-project.org/web/packages/lmtest/index.html>
- Uriel, E. (2013). Relajación de los supuestos en el modelo lineal clásico, 16-30.

Recuperado de [https://www.uv.es/uriel/6\\_Relajacion\\_de\\_los\\_supuestos\\_en\\_el\\_modelo\\_lineal\\_clasico.pdf](https://www.uv.es/uriel/6_Relajacion_de_los_supuestos_en_el_modelo_lineal_clasico.pdf)

USDA. (2017). Soil Survey Manual, (18). Recuperado de [https://www.nrcs.usda.gov/wps/portal/nrcs/detailfull/soils/ref/?cid=nrcs142p2\\_054262](https://www.nrcs.usda.gov/wps/portal/nrcs/detailfull/soils/ref/?cid=nrcs142p2_054262)

Vega, A., Ruíz, P., & Garro, J. (2017). Vehículos aéreos no tripulados de Lanammeucr: Una herramienta multidisciplinaria adaptada para todo tipo de condiciones al servicio del país. *Repositorio de la Universidad de Costa Rica*, 8(4), 8. Recuperado de <https://www.lanamme.ucr.ac.cr/repositorio/bitstream/handle/50625112500/911/Boletin-4-Vehiculos-aereos-no-tripulados.pdf?sequence=1&isAllowed=y>

Wang, H., Mortensen, A. K., Mao, P., Boelt, B., & Gislum, R. (2019). Estimating the nitrogen nutrition index in grass seed crops using a UAV-mounted multispectral camera. *International Journal of Remote Sensing*, 40(7), 2467-2482. <https://doi.org/10.1080/01431161.2019.1569783>

Wang, M., Shi, S., Lin, F., Hao, Z., Jiang, P., & Dai, G. (2012). Effects of soil water and nitrogen on growth and photosynthetic response of Manchurian ash (*Fraxinus mandshurica*) seedlings in northeastern China. *PloS one*, 7(2), e30754. <https://doi.org/10.1371/journal.pone.0030754>

Wang, Y., Liao, Q., Yang, G., Feng, H., Yang, X., & Yue, J. (2016). Comparing broad-band and red edge-based spectral vegetation indices to estimate nitrogen concentration of crops using casi data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 41(July), 137-143. <https://doi.org/10.5194/isprsarchives-XLI-B7-137->

2016

Williams, R. (2015). Heteroskedasticity. *University of Notre Dame*, 1-16.

Recuperado de <https://www3.nd.edu/~rwilliam/stats2/125.pdf>

Xie, Q., Dash, J., Huang, W., Peng, D., Qin, Q., Mortimer, H., ... Ye, H. (2018).

Vegetation Indices Combining the Red and Red-Edge Spectral Information for Leaf Area Index Retrieval. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(5), 1482-1492.

<https://doi.org/10.1109/JSTARS.2018.2813281>

Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033.

<https://doi.org/10.1080/01431160600589179>

Zelad, C. (2017). RPubS - Funciones Principales de la Librería Caret.